



TESIS - TI142307

# **MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION***

HASAN BISRI  
02411650010002

DOSEN PEMBIMBING  
Prof. MOSES L. SINGGIH, MSc, MRegSc, PhD

PROGRAM MAGISTER  
BIDANG KEAHLIAN MANAJEMEN KUALITAS DAN MANUFAKTUR  
DEPARTEMEN TEKNIK INDUSTRI  
FAKULTAS TEKNOLOGI INDUSTRI  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018



TESIS - TI142307

# **MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION***

HASAN BISRI  
02411650010002

DOSEN PEMBIMBING  
Prof. MOSES L. SINGGIH, MSc, MRegSc, PhD

PROGRAM MAGISTER  
BIDANG KEAHLIAN MANAJEMEN KUALITAS DAN MANUFAKTUR  
DEPARTEMEN TEKNIK INDUSTRI  
FAKULTAS TEKNOLOGI INDUSTRI  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018



THESIS - TI142307

# **ELIMINATING AUTOCORRELATION IN SHEWHART CONTROL CHART USING RESIDUAL CONTROL CHART BASED ON EXTENSION SUPPORT VECTOR REGRESSION MODEL**

HASAN BISRI  
02411650010002

SUPERVISOR  
Prof. MOSES L. SINGGIH, MSc, MRegSc, PhD

MASTER PROGRAM  
MANUFACTURE AND QUALITY MANAGEMENT  
DEPARTMENT OF INDUSTRIAL ENGINEERING  
FACULTY OF INDUSTRIAL TECHNOLOGY  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2018



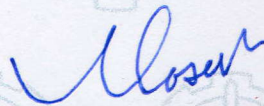
# MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION*

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Teknik (MT)  
di  
Institut Teknologi Sepuluh Nopember Surabaya

Oleh :  
**HASAN BISRI**  
NRP. 02411650010002

Tanggal Ujian : 5 Juni 2018  
Periode Wisuda : September 2018

Disetujui oleh :




1. Prof. Ir. Moses Laksono Singgih, M.Sc, M.Reg.Sc, Ph. D, IPU (Pembimbing)  
NIP: 19590817 198703 1002




2. Dr. Ir. Mokh Suef, M.Sc (Eng) (Penguji 1)  
NIP: 19650630 199003 1002



3. Putu Dana Karningsih ST, M.Eng.Sc, Ph.D (Penguji 2)  
NIP: 19740508 199903 2001



Dekan Fakultas Teknologi Industri,

  
Dr. Bambang Lelono Widjiantoro, ST., MT.  
NIP: 196905071995121001

## LEMBAR PERNYATAAN KEASLIAN TESIS

Saya yang bertanda tangan dibawah ini:

Nama : Hasan Bisri

NRP : 02411650010002

Program Studi : Magister Teknik Industri - ITS

menyatakan bahwa isi sebagian atau keseluruhan tesis saya yang berjudul:

**“MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION*”**

adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan, dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Seluruh referensi yang dikutip dan dirujuk telah saya tulis secara lengkap di daftar pustaka. Apabila kemudian hari ternyata pernyataan saya tidak benar, maka saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Surabaya, Juni 2018  
Yang membuat pernyataan

Hasan Bisri  
NRP. 02411650010002

# **MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION***

Nama Mahasiswa : Hasan Bisri  
NRP : 02411650010002  
Dosen Pembimbing : Prof. Moses L. Singgih, MSc, MRegSc, PhD

## **ABSTRAK**

Kualitas merupakan faktor kunci yang mengarahkan kepada keberhasilan, pertumbuhan, dan daya saing bisnis. Kualitas juga merupakan salah satu faktor penting dalam pengambilan keputusan konsumen dalam pemilihan produk dan layanan. Guna meningkatkan kualitas produk dapat memanfaatkan beberapa cara, salah satunya adalah menerapkan *statistical process control* (SPC). Salah satu *tool* SPC yang paling banyak diterapkan adalah diagram kontrol yang berguna untuk mengetahui variansi dari proses. Diagram kontrol didasarkan pada asumsi bahwa data mengikuti distribusi normal dan tidak terdapat hubungan antara pengamatan yang berurutan (autokorelasi). Namun dalam proses industri kontinyu kebanyakan data bersifat autokorelasi. Agar bisa menggunakan diagram kontrol secara efektif, autokorelasi dalam data harus dihilangkan. Langkah yang dapat dilakukan untuk pengendalian kualitas pada data autokorelasi adalah dengan memetakan *residual* hasil pemodelan menggunakan metode *time series* pada diagram kontrol. Pada penelitian ini dikembangkan diagram kontrol *residual* berdasarkan model *extention Support vector regression* yaitu *Least square support vector regression* dan *Genetic algorithm support vector regression* untuk mengatasi kasus autokorelasi pada proses. Kriteria kebaikan model dalam penelitian ini menggunakan nilai *Root Mean Square Error* (RMSE). Semakin kecil nilai RMSE maka model yang digunakan semakin baik. Setelah dilakukan perhitungan menggunakan metode regresi, *Support vector regression* dan metode *Extention support vector regression*, metode yang paling baik adalah *Genetic algorithm support vector regression* berdasarkan nilai RMSE sebesar 1,554310 dan 0,5565.

**Kata kunci** : Autokorelasi, Diagram Kontrol, *Least Square*, *Genetic Algorithm*, *Support Vector Regression*, Diagram Kontrol *Residual*



# **ELIMINATING AUTOCORRELATION IN SHEWHART CONTROL CHART USING RESIDUAL CONTROL CHART BASED ON EXTENSION SUPPORT VECTOR REGRESSION**

**By : Hasan Bisri**  
**Student Identity Number : 02411650010002**  
**Supervisor : Prof. Moses L. Singgih, MSc, MRegSc, PhD**

## **ABSTRACT**

Quality is a key factor that leads to business success, growth, and competitiveness. Quality is also an important factor in consumer decision making in the selection of products and services. In order to improve product quality can utilize several ways, one of them is apply statistical process control (SPC). One of the most widely applied SPC tools is the control chart which is useful for knowing the variance of the process. The control chart is based on the assumption that data follows a normal distribution and there is no relationship between successive observations (autocorrelation). But in the process of continuous industry most data are autocorrelation. In order to use the control chart effectively, autocorrelation in the data must be eliminated. Steps that can be done to control the quality of the autocorrelation data is to map the residual results of modeling using time series method in the control chart. In this research, the residual control charts are developed based on the extension support vector regression model that is Least square support vector regression and Genetic algorithm support vector regression to overcome the case of autocorrelation in the process. Criteria of model goodness in this research use Root Mean Square Error (RMSE). The smaller the value of RMSE then the model used the better. After calculation using regression method, Support vector regression and Extension support vector regression method, the best method is Genetic algorithm support vector regression based on RMSE value of 1.554310 and 0.5565.

**Keywords :** Autocorrelation, Control Chart, Least Square, Genetic Algorithm, Support Vector Regression, Residual Control Chart.

## KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT atas limpahan rahmat dan rezeki-Nya sehingga penulis dapat menyelesaikan penulisan Tesis yang berjudul **“MENGHILANGKAN AUTOKORELASI PADA DIAGRAM KONTROL SHEWHART MENGGUNAKAN DIAGRAM KONTROL RESIDUAL BERDASARKAN MODEL *EXTENTION SUPPORT VECTOR REGRESSION*”** dengan baik dan tepat waktu. Tak lupa juga shalawat serta salam tercurahkan kepada junjungan Nabi Muhammad SAW yang telah menyampaikan petunjuk kepada umatnya.

Laporan tesis ini diajukan sebagai syarat untuk menyelesaikan studi Strata 2 (S2) di Jurusan Teknik Industri. Selama pelaksanaan dan penyusunan tesis ini, penulis telah menerima bantuan dari berbagai pihak. Oleh sebab itu, pada kesempatan ini, penulis tidak lupa mengucapkan terima kasih dan penghargaan kepada:

1. Allah SWT yang telah memberikan kemudahan, kelancaran dan keyakinan kepada penulis, bahwa penulis mampu menyelesaikan Tesis ini;
2. Kedua orang tua, dan kakak-kakak yang senantiasa mendoakan dan memotivasi penulis;
3. Bapak Prof. Moses L. Singgih, MSc, MRegSc, PhD, selaku dosen pembimbing penulis yang telah memberikan pengarahan dan bimbingan selama penulis menyelesaikan Tesis ini;
4. Bapak Dr. Ir. Mokh. Suef, M.Sc (Eng) dan Ibu Putu Dana Karningsih ST, M.Eng.Sc, Ph.D. selaku dosen penguji sidang tesis atas segala saran dan kritik yang diberikan demi kesempurnaan tesis ini.
5. Teman – teman Pasca Sarjana Teknik Industri Periode Ganjil 2016/2017 yang telah memberikan bantuan dan memotivasi penulis dalam menyelesaikan Tesis ini.
6. Teman – teman residensi program magister, doktoral Teknik Industri ITS, program sarjana Teknik Industri ITS yang selalu menemani dan memotivasi.



Dalam penulisan Tesis ini, penulis merasa masih banyak kekurangan pada teknis penulisan dan materi laporan. Untuk itu, kritik dan saran dari semua pihak sangat diharapkan demi penyempurnaan pembuatan Tesis ini. Penulis berharap semoga Tesis ini dapat bermanfaat bagi objek amatan dan rekan – rekan di Teknik Industri ITS pada khususnya.

Surabaya, Juni 2018

Penulis

## DAFTAR ISI

BAB 1	PENDAHULUAN .....	1
1.1	Latar Belakang .....	1
1.2	Rumusan Masalah .....	5
1.3	Tujuan Penelitian.....	6
1.4	Manfaat Penelitian.....	6
1.5	Batasan Penelitian .....	7
1.6	Sistematika Penulisan.....	7
BAB 2	TINJAUAN PUSTAKA .....	9
2.1	Kualitas.....	9
2.1.1	Definisi Kualitas Produk.....	9
2.1.2	Dimensi dan Pengukuran Kualitas.....	9
2.2	Diagram Kontrol ( <i>Control Chart</i> ).....	11
2.2.1	Definisi Diagram Kontrol .....	11
2.2.2	Bentuk Diagram Kontrol.....	11
2.2.3	Individual <i>Control Chart</i> .....	14
2.3	Normalitas Data.....	14
2.4	Autokorelasi .....	16
2.4.1	<i>Sample Autocorrelation Function</i> .....	16
2.5	Diagram Kontrol Pada Data Yang Berautokorelasi .....	17
2.6	<i>Residual Control Chart</i> .....	18
2.7	<i>Support Vector Regression</i> .....	19
2.8	<i>K-Fold Cross Validation</i> .....	23
2.9	<i>Algoritma Genetika</i> .....	24
2.10	<i>Least Square Support Vector Regression</i> .....	27

2.11	Penelitian Terdahulu Tentang <i>Residual Control Chart</i> .....	29
2.12	Gap Penelitian dan Posisi Penelitian .....	36
BAB 3	METODOLOGI PENELITIAN .....	39
3.1	Diagram Alir.....	39
3.2	Perumusan Masalah.....	42
3.3	Pengujian Normalitas Data.....	42
3.4	Pengujian Autokorelasi .....	42
3.5	Perbandingan Metode Pemodelan .....	43
3.6	Residual Control Chart Berdasarkan LSSVR dan GASVR .....	43
3.7	Analisa dan Pembahasan .....	43
3.8	Kesimpulan dan Saran.....	43
BAB 4	PENGOLAHAN DATA .....	45
4.1	Data Penelitian .....	45
4.2	Statistik Deskriptif.....	48
4.3	Uji Normalitas .....	49
4.4	Diagram Kontrol Residual.....	51
4.5	LSSVR Dan GASVR .....	53
4.6	Diagram Kontrol Residual Berdasarkan LSSVR Dan GASVR .....	56
BAB 5	ANALISIS DAN INTERPRETASI HASIL.....	59
5.1	Statistik Deskriptif.....	59
5.2	Uji Normalitas .....	59
5.3	Diagram Kontrol Residual.....	60
5.4	LSSVR Dan GASVR .....	61
5.5	Diagram Kontrol Residual Berdasarkan LSSVR Dan GASVR .....	62
BAB 6	KESIMPULAN DAN SARAN .....	65
6.1	Kesimpulan.....	65

5.2	Saran.....	67
DAFTAR PUSTAKA .....		69
LAMPIRAN.....		73

*(Halaman ini sengaja dikosongkan)*

## DAFTAR GAMBAR

Gambar 2.1: Diagram Kontrol Statistik .....	12
Gambar 2.2: Diagram Kontrol Data Berdistribusi Normal.....	12
Gambar 2.3: Kurva Fungsi Kepekatan Peluang Distribusi Normal.....	15
Gambar 2.4: Diagram Kontrol Data Autokorelasi.....	16
Gambar 2.5: Metode Peramalan .....	19
Gambar 2.6: Pemetaan Data Dalam <i>Support Vector Machine</i> .....	20
Gambar 2.7: Pemetaan Struktur <i>Support Vector Regression</i> .....	20
Gambar 2.8: Regresi dengan tabung $\varepsilon$ -sensitive .....	21
Gambar 2.9: Ilustrasi K-Fold Cross Validation .....	24
Gambar 2.10: Ilustrasi Representasi Penyelesaian Masalah Dalam GA .....	25
Gambar 2.11: Diagram Alir Proses Kawin Silang.....	26
Gambar 2.12: Diagram Alir Proses Mutasi.....	27
Gambar 2.13: Alur Pemodelan LSSVR .....	29
Gambar 2.14: Pengembangan Pemodelan Diagram Kontrol Residual .....	31
Gambar 2.15: Pengembangan Metode Yang Digunakan Untuk Pemodelan .....	31
Gambar 3.1: Diagram Alir .....	39
Gambar 3.2: Alur Pemodelan Data Menggunakan GASVR .....	41
Gambar 4.1: Histogram Data Biaya Bahan Bakar .....	49
Gambar 4.2: QQ Plot Data Biaya Bahan Bakar.....	50
Gambar 4.3: Histogram Data Gani et al. (2010).....	50
Gambar 4.4: QQ Plot Data Gani et al. (2010).....	51
Gambar 4.5: Individual Control Chart Data <i>Training</i> Biaya Bahan Bakar .....	52
Gambar 4.6: Individual Control Chart Data <i>Testing</i> Biaya Bahan Bakar.....	52
Gambar 4.7: Individual Control Chart Data Gani et al. (2010) (SVR).....	53
Gambar 4.8: Plot Data <i>Testing</i> Data Biaya Bahan Bakar (LSSVR) .....	54
Gambar 4.9: Plot Data <i>Testing</i> Data Biaya Bahan Bakar (GASVR).....	54
Gambar 4.10: Plot Data Gani et al. (2010) (LSSVR) .....	55
Gambar 4.11: Plot Data Gani et al. (2010) (GASVR) .....	55
Gambar 4.12: Diagram Kontrol Residual Data Biaya Bahan Bakar (LSSVR) .....	56



Gambar 4.13: Diagram Kontrol Residual Data Gani et al. (2010) (LSSVR) .....	57
Gambar 4.14: Diagram Kontrol Residual Data Biaya Bahan Bakar (GASVR) .....	57
Gambar 4.15: Diagram Kontrol Residual Data Gani et al. (2010) (GASVR) .....	58

## DAFTAR TABEL

Tabel 2.1: Fungsi Kernel.....	23
Tabel 2.2: Ringkasan Jurnal Terdahulu .....	32
Tabel 2.3: Gap Penelitian.....	36
Tabel 4.1: Peubah dari Anggaran Keuangan Logistik .....	45
Tabel 4.2: Data Training Biaya Bahan Bakar .....	46
Tabel 4.3: Data Testing Biaya Bahan Bakar .....	47
Tabel 4.4: Data Penelitian Gani et al. (2010) .....	47
Tabel 4.5: Statistik Deskriptif Data Biaya Bahan Bakar .....	48
Tabel 4.6: Statistik Deskriptif Data Gani et al. (2010) .....	49
Tabel 4.7: Perbandingan Metode Pemodelan Data Biaya Bahan Bakar .....	55
Tabel 4.8: Perbandingan Metode Pemodelan Data Gani et al. (2010) .....	56

## DAFTAR LAMPIRAN

Lampiran 1.a Diagram Kontrol Individual DAC .....	73
Lampiran 1.b Diagram Kontrol Individual DA .....	73
Lampiran 2.a Uji Autokorelasi Data Aktual DAC.....	74
Lampiran 2.b Uji Autokorelasi Data Residual DAC Dari Model LSSVR .....	75
Lampiran 2.c Uji Autokorelasi Data Residual DAC Dari Model GASVR .....	76
Lampiran 3.a Koding Matlab Untuk Metode Pemodelan Data Dengan LSSVR.....	77
Lampiran 3.b Koding Rstudio Untuk Metode Pemodelan Data Dengan GASVR .....	77
Lampiran 4.a Fitness Plot Tiap Iterasi DAC .....	83
Lampiran 4.b Fitness Plot Tiap Iterasi DA .....	84

# BAB 1

## PENDAHULUAN

Pada pendahuluan akan dibahas hal yang berkaitan dengan latar belakang, perumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, asumsi dan sistematika penulisan.

### 1.1 Latar Belakang

Kualitas merupakan faktor kunci yang mengarahkan kepada keberhasilan, pertumbuhan, dan daya saing bisnis (Montgomery, 2013). Kualitas juga merupakan salah satu faktor penting dalam pengambilan keputusan konsumen dalam pemilihan produk dan layanan. Dalam situasi pasar saat ini dengan persaingan yang tinggi, kebanyakan perusahaan ditantang untuk menyediakan produk dan layanan kepada pelanggan dengan biaya rendah tanpa mempengaruhi kualitas produk (Thomasson dan Wallin, 2013). Oleh karena itu peningkatan kualitas merupakan keharusan bagi perusahaan agar tetap bisa menjaga keberlangsungan proses produksinya. Sebuah perusahaan yang bisa menyenangkan pelanggan dengan meningkatkan dan mengendalikan kualitas bisa mendominasi pesaing. Ada beberapa cara untuk meningkatkan kualitas produk, salah satunya adalah menerapkan *Statistical process control* (SPC). SPC digunakan untuk memantau, mengendalikan dan meningkatkan kualitas di banyak proses industri (MacCarthy dan Wasusri, 2002). Terdapat tujuh *tools* yang digunakan dalam SPC yaitu Diagram Pareto, Histogram, Diagram Kontrol, *Defect Concentration Diagram*, *Check Sheet*, Diagram Scatter dan Diagram Sebab Akibat (Montgomery, 2013).

Kandananond (2014) menyatakan bahwa salah satu *tool* SPC yang paling banyak diterapkan adalah diagram kontrol yang berguna untuk mengetahui variansi dari proses. Chongfuangprinya (2009) menyatakan bahwa diagram kontrol adalah grafik yang menampilkan hasil pengamatan waktu ke waktu dalam suatu periode tertentu. Diagram kontrol yang biasa digunakan adalah diagram kontrol Shewhart. Terdapat tujuh macam diagram kontrol Shewhart yang dibedakan berdasarkan jenis data yang diamati. Untuk data diskrit diagram kontrol Shewhart terdiri dari np-chart untuk mengidentifikasi jumlah total unit yang rusak (unit mungkin memiliki satu atau lebih cacat) dengan ukuran *sampling* konstan, p-chart digunakan ketika setiap unit dapat dianggap diterima atau tidak (tidak peduli jumlah cacat), juga menunjukkan jumlah kegagalan yang dideteksi (np) dibagi dengan jumlah unit total (n), u-chart digunakan untuk mendeteksi jumlah total cacat per unit (u) yang terjadi selama periode *sampling* dan dapat mendeteksi sampel

yang memiliki lebih dari satu cacat ketika jumlah sampel dari setiap periode *sampling* bervariasi secara signifikan dan c-chart digunakan ketika mengidentifikasi jumlah total cacat per unit (c) yang terjadi selama periode *sampling* ketika jumlah sampel dari setiap periode *sampling* sama. Sedangkan untuk data kontinu terdiri dari diagram kontrol  $\bar{X}$ -S digunakan ketika data dikumpulkan dalam subkelompok yang terdiri lebih dari 10 pengamatan, diagram kontrol  $\bar{X}$ -R digunakan ketika data dikumpulkan dalam subkelompok yang terdiri dari dua sampai 10 pengamatan, dan diagram kontrol Individual digunakan ketika satu titik data dikumpulkan pada setiap titik waktu. Diagram kontrol Shewhart telah digunakan dalam praktek selama beberapa dekade karena mudah digunakan dan diinterpretasikan. Di samping keunggulan ini, diagram kontrol Shewhart juga memiliki kelemahan diantaranya adalah dibutuhkan waktu lebih lama bagi diagram kontrol Shewhart untuk mendeteksi pergeseran rata-rata (Karaoglan, 2010). Selain itu, diagram kontrol Shewhart didasarkan pada asumsi bahwa data yang dihasilkan adalah independen antar pengamatannya. Menurut Bhattacharjee dan Samanta (2002) asumsi normalitas dan data independen harus dipenuhi agar bisa menerapkan SPC untuk suatu proses. Dalam situasi di mana asumsi normalitas dilanggar dalam derajat sedikit atau moderat, diagram kontrol akan tetap berfungsi dengan baik. Diagram kontrol akan memberikan hasil yang menyesatkan dalam bentuk terlalu banyak alarm palsu jika data berautokorelasi. Namun, asumsi independensi dari data tidak realistis dalam kenyataan (Demirkol, 2008). Dalam proses industri kontinu kebanyakan data bersifat autokorelasi (Basawa *et al.*, 1996). Seperti pada proses kimia di mana pengukuran berturut-turut pada proses sehingga karakteristik produk seringkali berkorelasi (Montgomery, 2013).

Autokorelasi adalah keadaan dimana antara pengamatan yang berurutan memiliki hubungan (Karaoglan, 2010). Autokorelasi antar data pengamatan dapat berasal dari berbagai faktor baik dari operator atau proses itu sendiri (Magaji *et al.*, 2015). Bila ada autokorelasi yang signifikan dalam sebuah proses, diagram kontrol tradisional dengan asumsi IID (*Independent Identic Distribution*) masih bisa digunakan namun tidak efektif. Menurut Montgomery dan Mastrangelo (1991) dalam Chaturvedi *et al.* (2015) kehadiran autokorelasi di antara pengamatan menyebabkan *false alarm* (baik itu tipe error I maupun tipe error II) dan kesimpulan yang menyesatkan tentang keadaan kontrol dari proses. Permasalahan bagaimana memonitor data yang berautokorelasi telah sering dibahas dalam beberapa tahun terakhir. Agar bisa menggunakan diagram kontrol secara efektif, autokorelasi dalam data harus dihilangkan. Psarakis (2007) menyatakan bahwa terjadi peningkatan *false alarm* (tipe error I) akibat dari penggunaan diagram kontrol biasa pada data berautokorelasi. Tipe error I adalah peristiwa proses dikatakan *out of control* meskipun produk tidak cacat, sedangkan tipe error II adalah peristiwa proses dikatakan *in control* meskipun ada

produk cacat (Montgomery, 2013). Pengambilan keputusan yang tidak tepat yang disebabkan oleh tipe *error* I akan dapat mengakibatkan penurunan pendapatan perusahaan dikarenakan perusahaan akan menolak suatu produk padahal produk itu seharusnya masih dalam keadaan terkontrol secara statistik. Langkah yang dapat dilakukan untuk melakukan pengendalian kualitas data berautokorelasi adalah dengan memetakan *residual* hasil pemodelan menggunakan metode *time series* pada *control chart* (Taylor *et al.*, 2007; Arkat *et al.*, 2007; Psarakis, 2007; Montgomery, 2013). Pemetaan *residual* ini disebut dengan diagram kontrol *residual*.

Penelitian- penelitian tentang pengembangan diagram kontrol *residual* diawali oleh Alwan dan Roberts (1988) yang menggunakan diagram kontrol *residual* berdasarkan model *Autoregressive Integrated Moving Average* (ARIMA). Penelitian lain tentang diagram kontrol *residual* dilakukan oleh Shao dan Lin (2013) adalah dengan memetakan *residual* dari model yang lebih sederhana yaitu menggunakan *Autoregressive* orde 1 (AR(1)). Selanjutnya Yu *et al.* (2015) membuat model prediksi dari data pengamatan dengan menggunakan *back propagation neural network*, selisih dari data pengamatan dan hasil pemodelan diplotkan pada diagram kontrol *Moving Range* (M-R). Issam dan Mohamed (2008) melakukan penelitian untuk memperoleh nilai *residual* berdasarkan model *support vector regression* (SVR) yang dipetakan dalam *Cumulative Sum* (CUSUM) *chart* untuk data multivariat. Du dan Lv (2013) melakukan penelitian dengan menggunakan *Minimal Euclidean Distance* (MED) berdasarkan *support vector regression* (SVR) dimana kernel yang dipakai adalah *hybrid kernel* yaitu penggabungan antara kernel *Gaussian Radial Basis Function Kernel* (GRBF) dan kernel Polinomial. Gani *et al.* (2010) melakukan penelitian tentang diagram kontrol *residual* berdasarkan model *support vector regression* (SVR), dimana tujuan utama penelitian ini adalah untuk membandingkan kinerja antara metode *Ordinary Least Square* (OLS) pada regresi, *Partial Least Square* (PLS), dan SVR dalam diagram kontrol *residual*. Ada dua kunci utama yang menjadikan SVR metode yang sukses dan berguna, terutama dalam teknik pemrograman matematika dan fungsi-fungsi kernel. pemrograman kuadrat merupakan latar belakang matematika yang kuat untuk SVR dan memberikan solusi yang kompetitif. Penggunaan metode kernel memungkinkan metode SVR menjadi teknik yang memadai untuk menangani data linier dan nonlinier. Hasil penelitian menunjukkan bahwa SVR memberikan hasil yang kompetitif dibandingkan dengan OLS dan PLS dalam hal keakuratan model dan kinerja diagram kontrol.

Berdasarkan penelitian- penelitian yang dilakukan terbukti bahwa diagram kontrol *residual* lebih sesuai untuk diterapkan pada data yang berautokorelasi. Kesimpulan lain yang didapatkan adalah bahwa metode ARIMA dan *support vector regression* dapat digunakan untuk pemodelan data yang berautokorelasi. Namun pemilihan metode pemodelan dapat mempengaruhi kinerja



diagram kontrol sesuai dengan kesimpulan pada penelitian Zhou dan Goh (2015) yang menyatakan bahwa keakuratan model yang dipakai sangat penting dalam menentukan kinerja diagram kontrol. Semakin akurat model yang dipakai maka hasil prediksi akan mendekati nilai aktualnya sehingga nilai *residual* yang didapatkan akan semakin mendekati nol. Semakin banyak nilai *residual* yang mendekati nol maka rata-ratanya akan berkisar pada nol dan titik data akan menyebar disekitar nilai rata-rata sehingga akan mengurangi tipe *error* I. Berkurangnya tipe *error* I akan berdampak pada jumlah produk yang di tolak sehingga akan meningkatkan pendapatan perusahaan. Seperti penggunaan metode ARIMA masih mempunyai kekurangan yaitu kurang sesuai dengan data yang tidak linier sehingga keakuratan pemodelannya masih belum terlalu tinggi jika data tidak linier. Metode lain yang biasanya digunakan pada pemodelan data adalah *Support vector regression* seperti pada penelitian Gani *et al.* (2010) dan Du dan Lv (2013). Metode pemodelan dengan menggunakan *Support vector regression* masih memiliki kekurangan yaitu sering memakan waktu dan memiliki beban komputasi yang lebih tinggi dikarenakan *Support vector regression* diselesaikan dengan menggunakan metode pemrograman kuadrat yang rumit dan mengandung *constraint* yang berupa pertidaksamaan. Pada penelitian Gani *et al.* (2010) didapatkan diagram kontrol residual yang lebih baik dibandingkan diagram kontrol dari data aktual. Dalam penelitian ini digunakan metode *support vector regression* dengan kernel RBF. Namun, karena metode *support vector regression* yang digunakan dalam penelitian ini menggunakan parameter yang kurang optimal, maka hal ini mempengaruhi hasil pemodelan data. Dikarenakan hasil pemodelan yang masih kurang akurat, didapatkan diagram kontrol *residual* yang memiliki titik yang keluar batas kontrol padahal kondisi aktual data seharusnya data terkontrol secara statistik.

Penelitian tentang diagram kontrol *residual* tidak terbatas pada area produksi saja namun juga pada area keuangan perusahaan. Bidang keuangan perusahaan bertanggung jawab untuk merencanakan dan mengendalikan anggaran. Karena itu, perlu untuk memantau, memahami dan mengendalikan variabilitas proses keuangan. Penelitian tentang diagram kontrol pada area keuangan perusahaan masih relatif baru dan belum banyak dilakukan. Salah satu penelitian mengenai diagram kontrol pada area keuangan adalah yang dilakukan oleh Pérez-Rave *et al.* (2017). Pada penelitian ini Pérez-Rave *et al.* (2017) menggunakan model regresi untuk mengatasi adanya autokorelasi pada data, namun dari hasil pemodelan didapatkan bahwa hasil pemodelan kurang akurat dikarenakan model yang digunakan kurang sesuai dengan data. Hal ini dikarenakan model regresi memerlukan banyak asumsi yang harus dipenuhi sehingga tidak dapat menggambarkan keadaan data secara lebih terperinci. Dikarenakan hasil pemodelan yang kurang akurat, didapatkan diagram kontrol dengan titik yang terletak pada garis batas, padahal titik data

tersebut seharusnya terkontrol secara statistik. Dalam penelitian Gani *et al.* (2010) dan Pérez-Rave *et al.* (2017) terlihat bahwa diagram kontrol yang dihasilkan masih mengandung titik data *residual* yang terletak pada garis batas kontrol yang menyebabkan menurunnya kinerja dari diagram kontrol. Dari kedua penelitian didapatkan kesimpulan bahwa ketepatan metode pemodelan dapat mempengaruhi kinerja diagram kontrol. Penelitian yang akan dilakukan adalah guna mengembangkan penelitian terdahulu, yaitu dengan mengoptimalkan parameter *support vector regression* dengan metode yang sistematis dikarenakan pada penelitian- penelitian yang telah dilakukan parameter nya ditentukan secara subjektif, selain itu alternatif lain adalah dengan menghilangkan batasan pertidaksamaan pada *constraint* model *Support vector regression* sehingga akan berdampak pada meningkatnya ketepatan dalam pengambilan kesimpulan dari diagram kontrol dan mepercepat proses perhitungan. Diagram kontrol yang digunakan adalah diagram kontrol individual dikarenakan satu titik data dikumpulkan pada setiap titik waktu.

## 1.2 Rumusan Masalah

Penggunaan diagram kontrol pada suatu proses sering kali menampilkan hasil yang berbeda dengan kenyataan (tipe *error I*). Perbedaan ini akan menyebabkan kesalahan dalam pengambilan kesimpulan sehingga menyebabkan kesalahan penanganan masalah dalam proses produksi yang akan menyebabkan variansi proses semakin besar dan berakibat pada menurunnya kualitas produk. Banyaknya kejadian seperti ini dikarenakan adanya kejadian autokorelasi sehingga memerlukan pengontrolan kualitas menggunakan sebuah diagram kontrol untuk data berautokorelasi. Dalam penelitian Gani *et al.* (2010) dan Pérez-Rave *et al.* (2017), untuk menghilangkan autokorelasi dalam data digunakan metode pemodelan yang selanjutnya *residual* dari pemodelan diplotkan pada diagram kontrol individual. Gani *et al.* (2010) menggunakan metode *Support vector regression* untuk melakukan pemodelan, sedangkan Pérez-Rave *et al.* (2017) memodelkan data autokorelasi dengan menggunakan metode regresi linier berganda. Namun dalam kedua penelitian tersebut terlihat bahwa diagram kontrol yang dihasilkan masih mengandung titik data *residual* yang terletak pada garis batas kontrol yang menyebabkan menurunnya kinerja dari diagram kontrol. Berdasarkan kesimpulan dari penelitian Zhou dan Goh (2015), keakuratan model yang dipakai sangat penting dalam menentukan kinerja diagram kontrol. Menurut Santosa (2007) tidak ada model yang terbaik untuk semua data. Dalam suatu data biasanya diterapkan beberapa metode dengan parameter yang berbeda, selanjutnya *residual* dari masing- masing metode dihitung, metode dengan *residual* terkecil adalah metode yang paling sesuai. Kriteria untuk membandingkan metode dapat menggunakan *Root Mean Square Error* (RMSE). RMSE mengambil akar kuadrat dari rata-rata kesalahan kuadrat memiliki beberapa implikasi. Karena kesalahan dikuadratkan

sebelum dirata-ratakan, RMSE memberikan bobot yang relatif tinggi terhadap kesalahan besar. Ini berarti RMSE lebih berguna ketika kesalahan besar sangat tidak diinginkan.

### 1.3 Tujuan Penelitian

Adapun tujuan dilakukannya penelitian ini adalah :

1. Membandingkan *Least Square Support Vector Regression* (LS-SVR) dan *Genetic Algorithm Support Vector Regression* (GA-SVR) dengan metode pemodelan pada penelitian Gani *et al.* (2010) dan Pérez-Rave *et al.* (2017) berdasarkan nilai *Root Mean Square Error* (RMSE).
2. Menggunakan diagram kontrol *residual* berdasarkan *Least Square Support Vector Regression* (LS-SVR) dan *Genetic Algorithm Support Vector Regression* (GA-SVR) pada data yang berautokorelasi.
3. Membandingkan diagram kontrol Residual hasil penelitian dengan pengontrolan kualitas pada penelitian Gani *et al.* (2010) dan Pérez-Rave *et al.* (2017).

### 1.4 Manfaat Penelitian

Manfaat yang bisa diperoleh dengan dilakukannya penelitian ini adalah:

1. Menghasilkan metode pemodelan *Least Square Support Vector Regression* dan *Genetic Algorithm Support Vector Regression* yang lebih sesuai digunakan untuk memodelkan data dibandingkan dengan metode pemodelan lainnya sehingga akan meningkatkan kinerja diagram kontrol.
2. Menghasilkan diagram kontrol *residual* berdasarkan metode pemodelan *Least Square Support Vector Regression* dan *Genetic Algorithm Support Vector Regression* (GA-SVR) yang digunakan untuk permasalahan data yang mengalami autokorelasi sehingga tidak terjadi kesimpulan yang salah terhadap kondisi proses.
3. Membantu mempermudah mengidentifikasi produk-produk yang *out of control* yang disebabkan oleh autokorelasi.

## 1.5 Batasan Penelitian

Batasan yang digunakan dalam penelitian ini adalah:

1. Penelitian ini berfokus pada pengendalian kualitas dengan menggunakan diagram kontrol individual.
2. Kriteria ketepatan metode pemodelan didasarkan pada nilai *Root Mean Square Error* (RMSE) .

## 1.6 Sistematika Penulisan

Penulisan laporan thesis ini terdiri dari beberapa dengan sistematika penulisan sebagai berikut:

### **Bab I** : Pendahuluan

Pada bab ini berisi tentang latar belakang permasalahan, perumusan masalah, tujuan penelitian, manfaat penelitian, batasan dan asumsi penelitian, sistematika penulisan.

### **Bab II** : Tinjauan Pustaka

Pada bab ini berisi tentang teori yang digunakan sebagai dasar penelitian tentang *Least Square Support Vector Regression* (LS-SVR), *Genetic Algorithm Support Vector Regression* (GA-SVR) dan *residual control chart*.

### **Bab III** : Metodologi Penelitian

Pada bab ini berisi langkah-langkah penelitian serta *flowchart* penelitian yang digunakan sebagai acuan dalam melakukan penelitian sehingga penelitian dapat berjalan secara sistematis, sesuai dengan tujuan yang telah ditetapkan.

### **Bab IV** : Pengumpulan dan Pengolahan Data

Pada bab ini berisi rekapitulasi data serta pengolahan data yang diperoleh. Pengolahan data dilakukan dengan menggunakan *Software* Rstudio, Matlab dan Minitab.

### **Bab V** : Analisis dan Interpretasi Hasil

Pada bab ini berisi tentang analisa dari hasil pengolahan data yang didapatkan.

## **Bab VI** : Kesimpulan dan Saran

Pada bab ini berisi tentang kesimpulan dari keseluruhan hasil yang telah didapatkan dengan menjawab tujuan penelitian dan juga saran yang dapat dilakukan untuk penelitian berikutnya.

## **BAB 2**

### **TINJAUAN PUSTAKA**

Bab tinjauan pustaka ini berisi tentang konten ilmiah yang menjadi dasar teori keilmuan dalam pelaksanaan penelitian ini, diantaranya dasar teori metode yang digunakan dan dasar teori dari penelitian serupa sebelumnya.

#### **2.1 Kualitas**

##### **2.1.1 Definisi Kualitas Produk**

Kualitas berarti kesesuaian untuk digunakan. Kualitas didasarkan pada sudut pandang bahwa produk dan layanan harus memenuhi persyaratan dari yang menggunakannya. Ada dua aspek umum kesesuaian untuk digunakan: kualitas desain dan kualitas kesesuaian. Variasi pada tingkatan kualitas memang disengaja yang disebut kualitas desain sedangkan kualitas kesesuaian adalah seberapa baik produk sesuai dengan spesifikasi yang telah didesain. Kualitas kesesuaian dipengaruhi oleh sejumlah faktor, antara lain pemilihan proses manufaktur, pelatihan dan pengawasan tenaga kerja, jenis pengontrolan proses, tes dan kegiatan inspeksi, prosedur yang benar, dan motivasi dari tenaga kerja untuk mencapai kualitas (Montgomery, 2013). Pengertian kualitas dapat berbeda-beda pada setiap orang dimana kemampuannya (*availability*), kinerja (*performance*), keandalan (*reliability*), kemudahan pemeliharaan (*maintainability*) dan karakteristiknya dapat diukur (Juran dan Godfrey, 1998). Ditinjau dari sudut pandang produsen, kualitas dapat diartikan sebagai kesesuaian dengan spesifikasinya (Juran dan Godfrey, 1998;Krajewski, at al., 2013). Suatu produk akan dinyatakan berkualitas oleh produsen, apabila produk tersebut telah sesuai dengan spesifikasinya.

##### **2.1.2 Dimensi dan Pengukuran Kualitas**

Kualitas produk bisa dijelaskan dan dievaluasi dengan beberapa cara. Montgomery (2013) menyatakan ada delapan komponen atau dimensi kualitas sebagai berikut:

1. *Performance* (Apakah produk akan menjalankan fungsinya), pelanggan biasanya mengevaluasi sebuah produk untuk menentukan apakah produk tersebut akan melakukan fungsi tertentu dan menentukan seberapa baik kinerjanya.
2. *Reliability* (Seberapa sering produk itu gagal), produk kompleks seperti banyak peralatan, mobil, atau pesawat terbang, biasanya akan memerlukan perbaikan selama masa kerjanya.



3. *Durability* (Berapa lama produk itu bertahan) adalah masa kerja produk yang efektif. Pelanggan menginginkan produk yang tetap baik dalam periode waktu yang lama.
4. *Serviceability* (Kemudahan untuk memperbaiki produk tersebut), banyak industri di mana pandangan konsumen tentang kualitas secara langsung dipengaruhi oleh seberapa cepat dan ekonomisnya perbaikan atau aktivitas perawatan rutin dapat dilakukan.
5. *Aesthetics* (Bentuk produk) adalah daya tarik visual produk yang juga memperhitungkan faktor-faktor seperti gaya, warna, bentuk, alternatif kemasan, karakteristik sentuhan, dan fitur sensoris lainnya.
6. *Features* (Apa yang dapat dilakukan produk), kebanyakan pelanggan menghubungkan kualitas tinggi dengan produk yang telah menambahkan fitur yang melebihi kinerja dasarnya.
7. *Perceived Quality* (Reputasi perusahaan atau produknya), reputasi masa lalu perusahaan mengenai kualitas produk secara langsung dipengaruhi oleh kegagalan dari produk yang sangat mudah terlihat, dan bagaimana pelayanan pelanggan ketika terjadi masalah pada produk akan menentukan reputasi perusahaan.
8. *Conformance to Standards* (Apakah produk dibuat persis seperti yang dirancang), biasanya produk disebut sebagai produk yang berkualitas tinggi ketika memenuhi persyaratannya.

Sebagian besar perusahaan merasa sulit (dan mahal) untuk menyediakan produk yang mempunyai karakteristik kualitas yang selalu identik dari unit ke unit, atau berada pada tingkat yang sesuai dengan harapan. Penyebab utama dari hal ini adalah variabilitas dalam setiap produk yang berakibat tidak adanya dua produk yang identik. Jika variasi kecil, maka hal itu mungkin tidak berdampak pada pelanggan. Namun, jika variasinya besar, maka pelanggan bisa menganggap unit tersebut tidak diinginkan dan tidak dapat diterima. Variabilitas hanya dapat dijelaskan dalam istilah statistik, metode statistik mengambil peran penting dalam upaya peningkatan kualitas. Dalam penerapan metode statistik terhadap kualitas, data diklasifikasikan pada karakteristik kualitas sebagai data atribut atau variabel. Data variabel biasanya ditandai dengan pengukuran kontinu, seperti panjang, tegangan, atau viskositas sedangkan data atribut biasanya adalah data diskrit yang sering berbentuk hitungan (Montgomery, 2013).

Nilai pengukuran yang sesuai dengan nilai yang diinginkan untuk karakteristik kualitas disebut nominal atau nilai target untuk karakteristik tersebut. Nilai target ini biasanya dibatasi oleh berbagai nilai yang paling khas dan cukup dekat ke sasaran sehingga tidak berdampak pada fungsi atau kinerja produk jika karakteristik kualitasnya berada dalam kisaran tersebut. Nilai terbesar yang diijinkan untuk karakteristik kualitas disebut batas spesifikasi atas (BSA), dan nilai terkecil yang diijinkan untuk karakteristik kualitas disebut batas spesifikasi bawah (BSB). Beberapa

karakteristik kualitas terkadang tidak memiliki dua batas spesifikasi namun juga bisa hanya memiliki batas pada satu sisi target (Montgomery, 2013).

## **2.2 Diagram Kontrol (*Control Chart*)**

### **2.2.1 Definisi Diagram Kontrol**

Diagram kontrol proses statistik adalah grafik data yang digunakan untuk membantu memahami, mengendalikan, dan memperbaiki proses, seperti pengendalian cacat atau kejadian buruk pada proses. Walaupun diagram kontrol berbasis teori statistik, namun mudah digunakan oleh praktisi untuk menafsirkan kondisi dari sebuah proses (Benneyan, 2001).

Diagram kontrol diperkenalkan oleh Walter A. Shewhart pada tahun 1920an. Diagram kontrol merupakan salah satu teknik utama pengendalian proses statistik (*Statistical Process Control*) (Montgomery, 2013). Diagram kontrol merupakan metode statistik yang telah berguna bagi praktisi untuk menghasilkan barang dan jasa yang berkualitas. Ada tiga kegunaan diagram kontrol kualitas. Pertama, membantu praktisi untuk membawa sebuah proses kepada keadaan yang terkontrol secara statistik. Kedua, bisa digunakan sebagai bantuan dalam membangun proses agar berada dalam keadaan terkendali secara statistik. Ketiga, diagram kontrol digunakan untuk membantu praktisi dalam memantau perubahan proses dari keadaan terkontrol secara statistik ke keadaan tidak terkontrol secara statistik (King, 2008).

Diagram kontrol juga menunjukkan adanya perubahan data dari waktu ke waktu, tetapi tidak menunjukkan penyebab penyimpangan meskipun penyimpangan itu terlihat. Dengan diagram kontrol:


- Dapat dibuat batas-batas guna melihat apakah hasil produksi menyimpang dari ketentuan yang disyaratkan.
- Dapat dengan mudah diawasi apakah proses dalam kondisi stabil atau tidak.
- Bila terjadi banyak penyimpangan pada produk dapat segera menentukan tindakan apa yang harus diambil.

### **2.2.2 Bentuk Diagram Kontrol**

Diagram kontrol digunakan untuk mendeteksi adanya penyimpangan dengan cara menetapkan batas-batas kendali:

1. *Upper Control Limit* / batas kendali atas (UCL), merupakan garis batas atas untuk suatu penyimpangan yang masih diperbolehkan.
2. *Central Line* / garis pusat atau tengah (CL), merupakan garis yang menunjukkan pusat dari karakteristik sampel.

3. *Lower Control Limit* / batas kendali bawah (LCL), merupakan garis batas bawah untuk suatu penyimpangan dari karakteristik sampel.




Gambar 2. 1 Diagram Kontrol Statistik (Russo et al., 2012)

Proses produksi dianggap tidak terkendali secara statistik ketika setidaknya salah satu dari pengamatan yang diamati pada grafik SPC mempunyai ciri- ciri sebagai berikut:

1. Ada titik di luar batas kontrol 3-sigma.
2. Setidaknya delapan poin berturut-turut ada di satu sisi grafik
3. Dua atau tiga poin berturut-turut berada di luar batas 2-sigma namun masih di dalam batas kontrol
4. Empat atau lima poin berturut-turut berada di luar batas 1-sigma
5. Pola yang tidak biasa atau tidak acak terjadi pada data, seperti pola siklik
6. Satu atau beberapa titik mendekati batas peringatan atau kontrol. (Omar, 2010)

Bentuk distribusi data dapat berupa data yang tidak normal yang membuat diagram kontrol menunjukkan plot data yang keluar dari batas kendali baik batas kendali atas maupun batas kendali bawah. Gambar 2.2 menunjukkan diagram kontrol dengan distribusi normal dari data pengamatan dan distribusi normal dari data rata-rata grup.



Gambar 2. 2 Diagram Kontrol Data Berdistribusi Normal (Sumber: Montgomery, 2013)

Diagram kontrol juga dapat digunakan untuk memperkirakan parameter sebuah proses produksi, dan melalui informasi tersebut dapat diketahui kapabilitas prosesnya. Diagram kontrol juga dapat memberikan informasi yang berguna dalam memperbaiki proses. Tujuan akhir dari pengendalian proses statistik adalah penghapusan variabilitas dalam proses. Pada kenyataannya tidak mungkin untuk benar-benar menghilangkan variabilitas, namun diagram kontrol adalah alat yang efektif dalam mengurangi variabilitas sebanyak mungkin (Montgomery, 2013)

Menurut Montgomery (2013) faktor-faktor yang mempengaruhi pengendalian kualitas yang dilakukan perusahaan adalah:

1. Kemampuan Proses, batas-batas yang ingin dicapai haruslah disesuaikan dengan kemampuan proses yang ada.
2. Spesifikasi yang berlaku, spesifikasi hasil produksi yang ingin dicapai harus dapat berlaku bila ditinjau dari segi kemampuan proses dan keinginan atau kebutuhan konsumen. Dalam hal ini haruslah dapat dipastikan dahulu apakah spesifikasi tersebut dapat berlaku dari kedua segi yang telah disebutkan sebelum pengendalian kualitas pada proses dapat dimulai.
3. Tingkat ketidaksesuaian yang dapat diterima, tujuan dilakukannya pengendalian suatu proses adalah dapat mengurangi produk yang berada di bawah standar seminimal mungkin. Tingkat pengendalian yang diberlakukan tergantung pada banyaknya produk yang berada dibawah standar yang dapat diterima.
4. Biaya kualitas, biaya kualitas sangat mempengaruhi tingkat pengendalian kualitas dalam menghasilkan produk dimana biaya kualitas mempunyai hubungan yang positif dengan terciptanya produk yang berkualitas.

Asumsi mendasar untuk proses statistik adalah data yang dihasilkan oleh proses yang terkontrol adalah identik dan independen yang mengikuti sebaran normal dengan rata-rata  $\mu$  dan standar deviasi  $\sigma$ . Namun, dalam proses kontinyu asumsi independen tidak selalu terjamin, terutama bila unit yang berurutan mempunyai hubungan dengan unit sebelumnya. Oleh karena itu, diagram kontrol standar mungkin menunjukkan frekuensi alarm palsu (*Error tipe I*) yang meningkat (Magaji *et al.*, 2015). Autokorelasi muncul pada data yang dihasilkan oleh proses kontinyu karena nilai parameter tertentu yang dipantau bergantung pada nilai parameter sebelumnya. Proses manufaktur berupa produk kontinyu seperti pembuatan makanan, bahan kimia, kertas dan produk kayu lainnya sering menunjukkan gejala autokorelasi (Psarakis dan Papaleonida, 2007).

### 2.2.3 Individual Control Chart

Dalam banyak situasi biasanya ditemukan ukuran sampel dari sebuah pengamatan adalah satu ( $n=1$ ) yang menyebabkan hanya terdapat satu buah pengamatan di setiap periodenya. Beberapa situasi seperti ini diantaranya:

1. Penggunaan inspeksi dan pengukuran teknologi otomatis, setiap unit yang diproduksi dianalisis sehingga tidak ada dasar untuk membuat subgrup.
2. Ketersediaan data relatif lambat, dan sulit untuk mengikuti ukuran sampel  $n > 1$  untuk diakumulasikan sebelum dianalisis. Interval yang panjang antar pengamatan akan menyebabkan masalah pada subgrup. Hal ini sering terjadi pada situasi manufaktur dan nonmanufaktur.
3. Pengukuran berulang pada proses berbeda dikarenakan kesalahan laboratorium atau analisis, seperti dalam banyak proses kimia.
4. Beberapa pengukuran diambil pada unit produk yang sama, seperti mengukur ketebalan oksida di beberapa lokasi yang berbeda pada *wafer* di manufaktur semikonduktor.
5. Pada proses pabrik, seperti pembuatan kertas, pengukuran pada beberapa parameter, seperti ketebalan lapisan *roll*, akan sedikit berbeda dan menghasilkan standar deviasi yang terlalu kecil jika tujuannya adalah untuk mengendalikan ketebalan lapisan sepanjang *roll*.
6. Pengukuran individu sangat umum terjadi pada banyak proses transaksi, bisnis, dan layanan karena tidak ada dasar untuk pembuatannya. Terkadang hal ini terjadi karena ada kesenjangan waktu yang besar antar aktivitas pelayanan.

Misalkan ada  $w$  sampel data dengan rata-rata  $\mu_w$  dan simpangan baku  $\sigma_w$  sehingga diagram kontrol individual dapat dituliskan sebagai berikut (Montgomery, 2013):

$$UCL = \mu_w + L \sigma_w \quad (2.1)$$

$$CL = \mu_w \quad (2.2)$$

$$LCL = \mu_w - L \sigma_w \quad (2.3)$$

dimana  $L$  adalah jarak batas kendali ke garis tengah. Teori umum diagram kontrol ini pertama kali diusulkan oleh Walter A. Shewhart, dan diagram kontrol yang dikembangkan sesuai dengan prinsip-prinsip ini sering disebut diagram kontrol Shewhart.

## 2.3 Normalitas Data


Asumsi dasar dalam penggunaan diagram kontrol adalah data proses saat terkontrol mengikuti distribusi normal dan independen dengan rata-rata  $\mu$  dan standar deviasi  $\sigma$ . Ada banyak

jenis distribusi data baik itu untuk data diskrit maupun kontinyu. Distribusi untuk data diskrit seperti Binom, Poisson, Hipergeometrik, Binom Negatif. Sedangkan distribusi untuk data kontinyu seperti Normal, Weibull, Lognormal, Eksponensial dan Gamma. Grafik dari distribusi Normal dapat dilihat pada kurva Normal. Peubah acak yang memiliki bentuk menyerupai distribusi Normal disebut dengan Peubah acak Normal (Walpole *et al.*, 2002).

Distribusi Gaussian atau normal adalah distribusi yang paling penting dalam teori statistik. Fungsi kepekatan peluang dari distribusi normal untuk variabel X ditentukan oleh mean-nya  $\mu$  dan variasinya  $\sigma^2$  yang dapat dinyatakan dengan persamaan 2.2 sebagai berikut (Broersen, 2006):

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad -\infty < x < \infty \quad (2.4)$$

Peluang bahwa variabel normal akan berada pada interval  $-1,96 < x < +1,96$  adalah 95%. Distribusi normal penting karena benar-benar ditentukan oleh momen pertama dan kedua. Gambar 2.3 menunjukkan kurva distribusi normal untuk rata-rata  $\mu = 0$  dan  $\sigma^2 = 1$ .



Gambar 2. 3 Kurva Fungsi Kepekatan Peluang Distribusi Normal (Sumber: Broersen, 2006)

Uji Normalitas dilakukan untuk mengetahui apakah data pengamatan mengikuti distribusi Normal atau tidak. Uji normalitas data dapat dilakukan dengan menggunakan dua cara yaitu menggunakan cara grafis atau dengan melakukan uji secara *exact* menggunakan pendekatan statistik. Salah satu cara yang sederhana untuk uji normalitas adalah secara grafis yaitu dengan *Histogram* atau *Normal Probability Plot*. *Histogram* lebih sederhana dan mudah dibuat namun jika sampel data kecil, *histogram* kurang baik untuk pengujian. *Normal Probability Plot* membandingkan distribusi kumulatif dari data aktual dengan distribusi kumulatif dari distribusi Normal. Bentuk kurva peluang distribusi Normal berupa garis diagonal, apabila sebaran data aktual berada di sekitar garis diagonal maka data dikatakan berdistribusi Normal (Hair *et al.*, 2010).

Cara lain untuk melakukan Uji Normalitas data adalah Uji Shapiro-Wilk. Data pengamatan harus mengikuti distribusi Normal sesuai dengan asumsi dalam SPC. Nilai statistik pengujian Shapiro-Wilk dapat ditunjukkan sebagai berikut (Shapiro & Wilk, 1965):



$$W = \frac{\sum_{i=1}^n (a_i y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.5)$$


dimana  $y_i$  merupakan amatan ke- $i$  dan  $\bar{y}$  adalah rata-rata sampel, sedangkan  $a_i$  dapat dituliskan sebagai:

$$\mathbf{a}_i = (a_1, \dots, a_n) = \frac{\mathbf{m}^T \mathbf{V}^{-1}}{(\mathbf{m}^T \mathbf{V}^{-1} \mathbf{V}^{-1} \mathbf{m})^2} \quad (2.6)$$

dan  $\mathbf{m} = (m_1, \dots, m_n)^T$  adalah nilai ekspektasi dari order statistik variabel random berdasarkan distribusi normal standar dan  $\mathbf{V}$  adalah matrix order statistik. Nilai  $W$  berada di rentang 0 sampai dengan 1. Nilai  $W$  yang kecil mengindikasikan data tidak berdistribusi normal, sedangkan semakin besar nilai  $W$  maka data akan cenderung berdistribusi normal (Shapiro & Wilk, 1965). Pengontrolan kualitas data pengamatan dilakukan dengan menggunakan diagram kontrol individual.

## 2.4 Autokorelasi

Asumsi paling penting dalam penggunaan diagram kontrol adalah independensi dari pengamatan. Diagram kontrol tidak bekerja dengan baik jika terdapat autokorelasi pada data meskipun autokorelasinya kecil. Secara khusus, diagram kontrol akan memberikan hasil yang menyesatkan dimana akan ada terlalu banyak alarm palsu ketika data berkautokorelasi.



Gambar 2. 4 Diagram Kontrol Data Autokorelasi (Sumber: Montgomery, 2013)

Autokorelasi menunjukkan korelasi antara deret waktu  $y_t$  dan nilai lagnya sendiri  $y_{t-1}$  yang dapat dituliskan:

$$y_t = \rho y_{t-1} + U_t \quad (2.7)$$

### 2.4.1 Sample Autocorrelation Function (Sample ACF)

*Autocorrelation Function* (ACF) adalah korelasi atau hubungan antar data pengamatan suatu deret berkala. *Sample ACF* merupakan alat penting untuk memeriksa hubungan (Cryer, 1986). Korelasi antara  $Y_t$  dan  $Y_{t+k}$  dapat dituliskan sebagai berikut:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (2.8)$$

di mana:

$r_k$  : koefisien autokorelasi sampel pada lag- $k$

$Y_t$  : pengamatan pada waktu ke- $t$

$\bar{Y}$  : rata-rata pengamatan

$Y_{t-k}$  : pengamatan pada waktu ke  $t - k$

## 2.5 Diagram Kontrol Pada Data Yang Berautokorelasi

Alwan dan Roberts (1988) mengembangkan diagram kontrol Shewhart *residual* yang disebut *special cause chart* (SCC) sebagai pendekatan yang umum untuk mendeteksi kemungkinan pergeseran rata-rata proses pada data autokorelasi yang dibentuk dengan menerapkan *residual* dari model *time series* berdasarkan data proses pada grafik SPC tradisional (Shewhart, CUSUM, EWMA dan sebagainya) (Magaji, *et al.*, 2015). Dalam grafik ini, selisih antara nilai prediksi dan data yang sebenarnya, yaitu *residual*, diasumsikan tidak berkorelasi secara statistik dan mengikuti distribusi normal. Ide dasar dalam penggunaan metode SCC adalah mengubah data autokorelasi asli menjadi satu set *residual* untuk selanjutnya melakukan pengamatan terhadap *residual* tersebut. Diagram kontrol Shewhart, CUSUM atau EWMA adalah diagram yang paling sering digunakan pada diagram kontrol *residual*.

Salah satu model *time series* yang paling sering digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA) yang dapat menghapus korelasi serial dari data. Jadi *residual* yang berasal dari model ini digunakan untuk mewakili proses yang sedang diamati.

Karaoglan dan Bayhan (2011) berpendapat, bila ada autokorelasi signifikan dalam proses data, diagram kontrol tidak bisa diterapkan secara langsung tanpa beberapa modifikasi. Tiga pendekatan umum, yaitu: (I) memodelkan proses pengamatan menggunakan *Autoregressive Integrated Moving Average* (ARIMA) dan kemudian menerapkan diagram kontrol tradisional untuk memetakan residualnya; (II) Menyesuaikan batas kontrol standar dalam diagram kontrol untuk memperhitungkan autokorelasi dari pengamatan proses; (III) menghilangkan autokorelasi dari pengamatan proses menggunakan teknik pengendali. Kandanand (2014) mencatat bahwa, upaya untuk menyesuaikan proses yang stabil untuk mengimbangi gangguan yang tidak diinginkan mungkin berimbas pada proses dan juga bisa menyebabkan variasi yang lebih banyak, dan yang terbaik adalah mengintegrasikan model peramalan ke alat SPC tradisional.

Beberapa peneliti mempelajari perilaku kinerja diagram kontrol dengan adanya autokorelasi, dan pengamatan mendasar adalah bahwa autokorelasi mempengaruhi kinerja diagram kontrol baik


variabel maupun diagram kontrol atribut. Menurut Alwan dan Roberts (1988), lebih dari 85% penerapan kontrol proses pada industri menampilkan batas kontrol yang salah karena autokorelasi dari proses pengamatan sehingga melanggar asumsi dasar diagram kontrol Shewhart. Reid dan Sanders (2011) menyatakan bahwa diagram kontrol variabel dapat digunakan untuk memantau karakteristik kualitas yang dapat diukur dan memiliki skala yang berkesinambungan. Statistik deskriptif seperti ukuran kecenderungan dan variasi sentral juga bisa sangat membantu dalam menggambarkan karakteristik tertentu dari suatu produk dan proses. Diagram kontrol untuk atribut di sisi lain, dapat digunakan untuk memantau karakteristik yang diskrit dan bisa dihitung dan terkadang hal ini dapat dicapai dengan keputusan 'ya' atau 'tidak' yang sederhana.

## 2.6 *Residual Control Chart*

Pada industri modern, proses produksi biasanya melibatkan sejumlah proses yang berkorelasi satu sama lain. Meskipun diagram kontrol individu univariat dapat diterapkan untuk memonitor parameter proses individual, namun bergantung pada diagram seperti itu dapat menyebabkan kesimpulan yang tidak efisien dan hasil yang tidak memuaskan. Sebaliknya, diagram kontrol multivariat yang memperhitungkan hubungan antara variabel proses dapat meningkatkan probabilitas *false alarm* (tingkat kesalahan Tipe I) untuk pemantauan proses (Woodall dan Montgomery, 1999; Johnson dan Wichern, 2007). Alwan dan Roberts (1988) juga memperkenalkan *Special Cause Chart* (SCC) yaitu dengan membentuk model ARIMA untuk proses autokorelasi. SCC bukan sebuah diagram kontrol sebenarnya, karena tidak memiliki batas kontrol, hanya terdiri dari plot data yang telah dimodelkan dengan model ARIMA. SCC adalah prakiraan yang diperoleh saat data difitkan dengan model *time series* yang tepat. Hal ini dimaksudkan untuk memberi gambaran tentang keadaan yang diprediksi dari karakteristik kualitas tanpa batasan kontrol (Samanta dan Bhattacharjee, 2001 dalam Magaji, *et al.*, 2015).

Alasan menggunakan diagram *residual* adalah asumsi bahwa model *time series* sesuai yaitu *residual* tidak berkorelasi. Diagram kontrol tradisional seperti X-chart (diagram individu), *Cumulative Sum* (diagram CUSUM) dan diagram *eksponential weighted moving average* (EWMA) kemudian dapat diterapkan ke *residual*. Namun, diagram *residual* tidak memiliki sifat yang sama dengan diagram tradisional. Harris dan Ross (1991) mengakui bahwa diagram *residual* dari proses *autoregresif* (orde 1) yang baru sekalipun mungkin memiliki kemampuan yang buruk untuk mendeteksi pergeseran rata-rata proses. Longnecker dan Ryan (1990) dalam Psarakis (2007) menunjukkan bahwa untuk proses AR (1), diagram *residual* memiliki probabilitas tinggi untuk mendeteksi pergeseran rata-rata segera setelah terjadi, namun jika diagram *residual* gagal mendeteksi pergeseran segera, maka kemungkinan kecil bahwa pergeseran akan terdeteksi

selanjutnya untuk proses AR (1) dengan autokorelasi positif. Gambar 2.5 menunjukkan metode prediksi yang digunakan untuk data *time series*.



Gambar 2. 5 Metode Peramalan (Sumber: Kaya et al., 2017)

## 2.7 Support Vector Regression


Algoritma *Support Vector* adalah generalisasi nonlinier dari algoritma *Generalized Portrait* yang dikembangkan di Rusia pada tahun enam puluhan (Vapnik dan Lerner 1963, Vapnik dan Chervonenkis 1964).

*Support vector machine* (SVM) memiliki dua sifat khusus yang dapat dicapai:

- (1) Generalisasi yang tinggi dengan memaksimalkan margin dan
- (2) Mendukung sebuah pembelajaran yang efisien dari fungsi nonlinier dengan trik kernel (Suganyadevi dan Babulal, 2014)

Untuk klasifikasi, SVM mencoba menemukan *hyperplane* optimal, yang dinyatakan sebagai kombinasi linier dari subset pelatihan data (disebut *support vectors*) dengan memecahkan masalah batasan linear *quadratic programming* (QP) dengan margin maksimal antara dua kelas. Namun, dengan diperkenalkannya *loss function  $\epsilon$ -insensitif* Vapnik, SVM telah diperluas untuk

memecahkan sebuah masalah estimasi regresi nonlinier yang disebut SVM untuk regresi atau *Support vector regression*.




Gambar 2. 6 Pemetaan Data dalam Support Vector Machine

(Sumber: Scolkopf & Smola, 2002)

*Support vector regression* (SVR) merupakan bentuk aplikasi yang paling umum dari *Support Vector Machine* (SVM) yang digunakan untuk permasalahan regresi. Tujuan SVR adalah untuk mendapatkan sebuah fungsi sebagai suatu *hyperplane* berupa fungsi regresi dimana terdapat kesesuaian dengan seluruh data input dengan sebuah *error* dan membuat  $\varepsilon$  sekecil mungkin (Schölkopf & Smola, 2002).

Pertama- tama SVR diilustrasikan dengan fungsi linier, selanjutnya permasalahan nonlinier bisa ditransformasi menjadi permasalahan linier dengan peta nonlinier dari ruang input dimensi yang lebih rendah ke ruang fitur dimensi yang lebih tinggi (Leksakul et al., 2015). Gambar 2.6 menunjukkan fungsi kernel yang dapat mengubah data menjadi ruang berdimensi lebih tinggi sehingga dimungkinkan untuk melakukan pemisahan.

Gambar 2.7 menunjukkan struktur dari *support vector regression* dalam memetakan fungsi regresi. Pemetaan *support vector regression* didasari oleh pemetaan data *input* menjadi ruang dimensi yang lebih tinggi dengan melalui pemetaan tidak linier menggunakan fungsi kernel.



Gambar 2. 7 Pemetaan Struktur Support Vector Regression (Sumber: Leksakul et al., 2015)

dimana:

$\hat{x}_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-(m-1)})$  ;  $\hat{x}_{t+1}$  adalah nilai prediksi dan  $\vec{x}_t$  adalah nilai amatan, sedangkan  $K(\vec{x}_i, \vec{x})$  adalah *dot-product* fungsi kernel yang sesuai (Suganyadevi, 2014)


SVR adalah fungsi yang didekati dengan menggunakan bentuk (Leksakul *et al.*, 2015):

$$f(x_t) = \langle w, x_t \rangle + b \quad (2.10)$$

dimana  $\langle ., . \rangle$  menandakan *dot product*  $X, X$  dalam *input space*,  $w$  adalah vektor *weight* dan  $b$  adalah bias. *Flatness* dalam persamaan (2.10) berarti mencari  $w$  sekecil mungkin. Salah satu cara untuk memastikan hal ini adalah meminimalkan persamaan *regularisasi*  $\|w\|^2 = (w, w)$ . Permasalahan ini dapat ditulis sebagai permasalahan optimasi *convex* sebagai berikut (Smola dan Scolkopf, 2004):

$$\text{minimize } \frac{1}{2} \|w\|^2 \quad (2.11)$$

$$\text{Subject to } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{cases} \quad (2.12)$$



Gambar 2. 8 Regresi dengan tabung  $\varepsilon$ -sensitive (Sumber: Burges, 1998)

Asumsi tersembunyi dalam persamaan (2.12) adalah bahwa fungsi  $f$  tersebut sebenarnya ada yang mendekati semua pasangan  $(x_i, y_i)$  dengan presisi  $\varepsilon$ , atau dengan kata lain, permasalahan optimasi *convex* memang layak dilakukan. Terkadang mungkin tidak menjadi masalah, atau mungkin juga dibiarkan beberapa kesalahan yang dianalogikan sebagai "soft margin" dari *loss function* (Bennett dan Mangasarian, 1992) yang digunakan pada *SV machine* oleh Cortes dan Vapnik (1995), salah satunya memperkenalkan variabel *slack*  $\xi_t$  dan  $\xi_t^*$  untuk mengatasi jika kendala pada masalah optimasi (2.12) tidak layak. Formulasi yang terdapat dalam Vapnik (1995) untuk mengakomodasi keadaan tersebut adalah:

$$\text{minimize } \frac{1}{2} \|w\|^2 + C \sum_{t=1}^T (\xi_t + \xi_t^*) \quad (2.13)$$

subject to:

$$y_t - \langle w, x_t \rangle - b \leq \varepsilon + \xi_t \quad (2.14)$$

$$\langle w, x_t \rangle + b - y_t \leq \varepsilon + \xi_t \quad (2.15)$$

$$\xi_t, \xi_t^*, C \geq 0 \quad (2.16)$$

Konstanta  $C > 0$  menentukan *trade-off* antara *flatness* dari  $f$  dan jumlah penyimpangan yang lebih besar dari toleransi  $\varepsilon$  (Smola & Scolkopf, 2004). *Loss function*  $\varepsilon$  -*insensitive* diterapkan untuk mengukur ketidaksesuaian antara kumpulan data dan fungsi interpolasi  $f(x_t)$  yang ditunjukkan dengan:

$$L(y_t, f(x)) = \begin{cases} 0 & ; \text{jika } |y_t - f(x)| \leq \varepsilon \\ |y_t - f(x)| - \varepsilon & ; \text{lainnya} \end{cases} \quad (2.17)$$

Kesalahan pada batasan atas dan bawah pada titik *training* dapat di estimasi dengan  $\xi_t, \xi_t^*$ . Bernilai nol untuk semua poin di dalam batasan (Leksakul et al., 2015).

Permasalahan optimasi pada persamaan (2.13) dapat diselesaikan dalam *dual form* menggunakan metode Lagrange yang dapat dituliskan sebagai berikut :

$$L = \frac{1}{2} \|w\|^2 + C \sum_{t=1}^l (\xi_t + \xi_t^*) - C \sum_{t=1}^l (\eta_i \xi + \eta_i^* \xi^*) - \sum_{t=1}^l \alpha_t (\varepsilon + \xi_t - y_t + \langle w, x_t \rangle + b) - \sum_{t=1}^l \alpha_t^* (\varepsilon + \xi_t^* - y_t + \langle w, x_t \rangle + b) \quad (2.18)$$

dimana  $L$  adalah fungsi Lagrange dan  $\eta_i, \eta_i^*, \alpha_t, \alpha_t^*$  adalah pengali Lagrange. Permasalahan dual pada persamaan 2.18 harus memenuhi  $\eta_i^*, \alpha_t^* \geq 0$ . Solusi dari persamaan 2.18 adalah dengan menurunkan parsial  $L$  dengan  $b, w$  dan  $\xi_t$  seperti berikut :

$$\frac{\partial L}{\partial b} = \sum_{t=1}^l (\alpha_t^* - \alpha_t) = 0 \quad (2.19)$$

$$\frac{\partial L}{\partial w} = w - \sum_{t=1}^l (\alpha_t^* - \alpha_t) x_t = 0 \quad (2.20)$$

$$\frac{\partial L}{\partial \xi_t^*} = (C - \alpha_t^* - \eta_t^*) = 0 \quad (2.21)$$

Kemudian substitusikan persamaan 2.19, 2.20 dan 2.21 kedalam persamaan 2.18 maka didapatkan :

$$\text{maximize } -\frac{1}{2} \sum_{t,u=1}^l (\alpha_t - \alpha_t^*)(\alpha_u - \alpha_u^*) \langle x_t, x_u \rangle - \varepsilon \sum_{t=1}^l (\alpha_t - \alpha_t^*) + \sum_{t=1}^l y_t (\alpha_t - \alpha_t^*) \quad (2.22)$$

subject to

$$\sum_{t=1}^l y_t (\alpha_t - \alpha_t^*) = 0 \text{ dan } \alpha_t, \alpha_t^* \in [0, C] \quad (2.23)$$

Dengan mempertimbangkan fungsi kernel, persamaan fungsi  $F(X)$  akan menjadi sebuah fungsi *linear* yang ditunjukkan dengan persamaan berikut:

$$F(x) = \sum_{i=1}^N (\alpha_i - \hat{\alpha}_i) K x_i x_j + b \quad (2.24)$$

dimana:

$K x_i x_j$  adalah fungsi Kernel  $k$

Beberapa jenis fungsi kernel umum digunakan dalam menyelesaikan permasalahan *support vector regression*. Berikut merupakan fungsi kernel yang dapat digunakan pada SVM (Karatzoglou *et al.*, 2006):


Tabel 2. 1 Fungsi Kernel

No	Fungsi Kernel	Formula
1	Linier	$H(\mathbf{x}, \mathbf{x}') = \langle \mathbf{x}, \mathbf{x}' \rangle$
2	Radial Basis Function	$H(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \ \mathbf{x} - \mathbf{x}'\ ^2)$
3	Polinomial	$H(\mathbf{x}, \mathbf{x}') = (\gamma \cdot \langle \mathbf{x}, \mathbf{x}' \rangle + c)^d$
4	Sigmoid	$H(\mathbf{x}, \mathbf{x}') = (\gamma \cdot \langle \mathbf{x}, \mathbf{x}' \rangle + c)$
5	Bessel	$H(\mathbf{x}, \mathbf{x}') = \frac{Bessel_{(v+1)}^n(\sigma \ \mathbf{x} - \mathbf{x}'\ )}{(\ \mathbf{x} - \mathbf{x}'\ )^{-n(v-1)}}$
6	Laplace Radial Basis Function	$H(\mathbf{x}, \mathbf{x}') = \exp(-\sigma \ \mathbf{x} - \mathbf{x}'\ )$
7	Radial Basis ANOVA	$H(\mathbf{x}, \mathbf{x}') = \left( \sum_{k=1}^n \exp(-\sigma \langle \mathbf{x}, \mathbf{x}' \rangle^2) \right)^2$
8	Linier Splines pada dimensi satu	$H(\mathbf{x}, \mathbf{x}') = 1 + \mathbf{x}\mathbf{x}' \min(\mathbf{x}, \mathbf{x}') - \frac{\mathbf{x} + \mathbf{x}'}{2} (\min(\mathbf{x}, \mathbf{x}')^2 + \frac{(\min(\mathbf{x}, \mathbf{x}')^3)}{3})$

## 2.8 K-Fold Cross Validation

*Cross-Validation* adalah metode statistik untuk mengevaluasi dan membandingkan algoritma pembelajaran dengan membagi data menjadi dua bagian: satu digunakan untuk *training* atau melatih model dan yang lain digunakan untuk memvalidasi model. *Cross Validation* digunakan untuk menemukan parameter terbaik dari satu model dengan cara menguji besarnya *error* pada data test (Santosa, 2007). Bentuk dasar dari *cross validation* adalah *k-fold cross-validation* (Refaeilzadeh *et al.*, 2016). Dalam *k-fold cross-validation*, data dipartisi terlebih dahulu ke dalam k bagian yang sama (atau hampir sama) atau set. Selanjutnya k iterasi pelatihan dan validasi dilakukan sedemikian rupa sehingga dalam setiap iterasi didapatkan set data validasi yang berbeda sedangkan sisa k-1 set digunakan untuk pelatihan. Gambar 2.9 menunjukkan proses *cross validation* dari suatu model:





Gambar 2. 9 Ilustrasi K-Fold Cross Validation

Ada dua kemungkinan tujuan dalam *cross validation*:

1. Untuk memperkirakan kinerja model yang dipelajari dari data yang tersedia menggunakan satu algoritma. Dengan kata lain, untuk mengukur kemampuan generalisasi suatu algoritma.
2. Untuk membandingkan kinerja dua atau lebih algoritma berbeda dan menemukan algoritma terbaik untuk data yang tersedia, atau alternatif untuk membandingkan kinerja dua atau lebih varian dari parameter model.

## 2.9 Algoritma Genetika

Algoritma Genetika (GA) adalah metode optimasi dan pencarian yang dikembangkan berdasarkan prinsip genetika dan seleksi alam berdasarkan Teori Evolusi Darwin (Holland, 1975). Dalam GA, populasi awal dari individu, masing-masing mempunyai kemungkinan untuk menjadi solusi dari permasalahan. Masing-masing individu berevolusi dengan operator genetik yaitu seleksi, kawin silang dan mutasi (Fernandez-Lozano *et al.*, 2016). Individu dapat dikatakan sama dengan kromosom yang merupakan kumpulan gen. Kromosom merupakan bagian penting dalam GA. Satu kromosom atau individu mewakili satu vektor solusi (Santosa & Willy, 2011). Representasi kromosom digunakan untuk mewakili suatu nilai solusi dengan bilangan biner yang memiliki nilai 0 atau 1. Panjang setiap kromosom bergantung pada ketelitian yang dikehendaki. Persamaan 2.25 menunjukkan perhitungan panjang kromosom yang harus disediakan dengan ketelitian yang dikehendaki.

$$r * 10^k \approx 2^n \quad (2.25)$$


di mana,

$r$  : Kisaran solusi

$k$  : Ketelitian dibelakang koma

$n+1$  : Banyaknya bit yang harus disediakan.

Gambar 2.10 menunjukkan hubungan antara Allele, Gen, Kromosom, Individu dan populasi sebagai berikut:



Gambar 2. 10 Ilustrasi Representasi Penyelesaian Masalah Dalam Algoritma Genetika

Pada algoritma genetika, persamaan 2.26 digunakan untuk merubah nilai *real* pada kisaran solusi sedangkan persamaan 2.27 merupakan representasi kromosom biner yang bertujuan untuk mengkonversi nilai biner menjadi bilangan *real* atau *decoding* dalam interval batas atas dan batas bawah:

$$int = \sum_{i=0}^n bit(i) * 2^i \quad (2.26)$$

$$solusi = min + (int * \frac{r}{2^{n+1}-1}) \quad (2.27)$$

di mana,

$bit(i)$  : Nilai bit ke- $i$  (0 atau 1)

$min$  : Nilai batas bawah solusi

$r$  : Kisaran solusi

Dalam GA untuk mengukur tingkat kebaikan suatu solusi dengan solusi yang dicari adalah menggunakan Fungsi *fitness*. Fungsi fitness yang biasa digunakan adalah sebagai berikut (Santosa & Willy, 2011):

$F(x) = \frac{1}{1+f(x)}$  untuk kasus minimasi fungsi objektif

dan


$F(x) = f(x)$  untuk kasus maksimasi fungsi objektif

Dimana  $f(x)$  adalah fungsi tujuan dari masalah yang ingin diselesaikan.

Nilai fitness menentukan kromosom mana yang akan diseleksi. Seleksi adalah proses untuk menentukan kromosom yang akan bertahan dalam populasi. Kromosom terpilih mempunyai kemungkinan untuk mengalami proses kawin silang (*crossover*) (Zukhri, 2014). Dengan nilai fitness yang tinggi maka kesempatan reproduksi bagi individu lebih besar dibandingkan individu lain dalam suatu populasi. Ada beberapa metode seleksi yaitu diantaranya metode roda *roulette*, dan turnamen.

Setelah proses seleksi selesai dilakukan maka langkah selanjutnya adalah kawin silang yang merupakan operator dalam Algoritma genetika yang melibatkan dua induk dengan tujuan untuk melahirkan kromosom baru (Zukhri, 2014). Proses kawin silang akan menghasilkan dua kromosom anak yang merupakan kombinasi gen dari dua kromosom induk. Nilai peluang *Crossover* ( $p_c$ ) akan menentukan frekuensi dari penyilangan.


Gambar 2.11 menunjukkan alur kawin silang pada algoritma genetika sebagai berikut:



Gambar 2. 11 Diagram Alir Proses Kawin Silang

Selanjutnya, mutasi adalah bagian penting dalam proses pencarian solusi untuk membantu mencegah populasi dari solusi lokal optimal (Arkeman et al., 2014). Mutasi bertujuan untuk

memunculkan individu baru yang berbeda sama sekali dengan individu yang sudah ada (Santosa & Willy, 2011). Dalam mutasi terdapat peluang mutasi ( $pm$ ). Probabilitas ini akan menentukan kromosom mana yang akan mengalami perubahan gen. Jika  $pm$  terlalu kecil, banyak gen yang mungkin berguna tidak pernah dievaluasi namun jika  $pm$  terlalu besar, maka terlalu banyak gangguan acak, sehingga anak kehilangan kemiripan dari induknya. Alur proses mutasi dapat dilihat pada Gambar 2.12 sebagai berikut:



Gambar 2. 12 Diagram Alir Proses Mutasi

## 2.10 Least Square Support Vector Regression

Least square support vector regression adalah variasi lain dari *Support vector regression*. SVR mengharuskan untuk menentukan dua *hyperparameter* ( $C$ ,  $\varepsilon$ ) yang memungkinkan model untuk disesuaikan dengan tugas yang berbeda. Namun, *hyperparameter*  $\varepsilon$  dapat dihilangkan ketika mempertimbangkan sebuah fungsi kerugian kuadrat terkecil dibandingkan fungsi kerugian  $\varepsilon$ -insensitif (Suykens *at al.*, 2002). Pembentukan *Least square support vector machine* (LS-SVM) ini mensyaratkan satu set persamaan linear diselesaikan, yang

mungkin menjadi jauh lebih sederhana daripada memecahkan persamaan kuadrat. Hasil penelitian terdahulu menunjukkan bahwa LS-SVM setidaknya seakurat SVM konvensional. Yang terpenting, berkurangnya jumlah *hyperparameter* untuk pemodelan regresi.

LS-SVR diusulkan oleh Suyken *et al.* (2002), yang didapatkan dari himpunan persamaan linier, bukan masalah pemrograman kuadratik seperti pada model SVR. Ada  $M$  titik data  $x_i, y_i, i=1, \dots, M$  dimana  $x_i \in \mathcal{R}^n$  adalah data input ke  $i$  dan  $y_i \in \mathcal{R}$  adalah output ke  $i$ . Formulasi LS-SVR dapat dilihat pada persamaan 2.22 sebagai berikut:

$$\min J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} C \sum_i^M e_i^2 \quad (2.22)$$

such that:

$$y_i = w^T \varphi(x_i) + b + e_i, i = 1, \dots, M \quad (2.23)$$

*Error* sekarang dilambangkan dengan  $e$  untuk menekankan bahwa  $e$  mewakili penyimpangan yang sebenarnya antara nilai aktual dan perkiraan dalam formulasi LS-SVR, bukan variabel *slack* yang diperlukan untuk memastikan *feasibility* (seperti pada SVR). Perbedaan yang paling mendasar dengan *Support Vector Regression* adalah pembatas yang berupa persamaan. Perbedaan ini membawa akibat yang signifikan dalam hal formulasi optimasi.  $w$  adalah pembobot (*weight*),  $C$  adalah parameter penalti,  $\varphi(\cdot)$  adalah fungsi pemetaan nonlinier,  $b_j \in \mathcal{R}$  adalah bias dan  $e_j = [e_{1j}, \dots, e_{Nj}]$  adalah vektor *error* dari prediksi data *training*. Untuk menemukan parameter  $w$  dan  $b$ , persamaan 2.22 diubah menjadi optimasi tanpa pembatas (*unconstrained optimization*) yaitu dengan persamaan *Lagrange* sebagai berikut:

$$L(w, b, e, \alpha) = J(w, e) - \sum_i^l \alpha_i \{ w^T \varphi(x_i) + b + e_i - y_i \} \quad (2.24)$$

dimana  $\alpha_i$  adalah *lagrange multiplier*. Solusi dari persamaan 2.24 didapatkan dengan menurunkan parsial dengan  $w, b, e$  dan  $\alpha$  sebagai berikut:

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_i^l \alpha_i \varphi(x_i) \quad (2.25)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_i^l \alpha_i = 0 \quad (2.26)$$

$$\frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = C e_i \quad i = 1, \dots, l \quad (2.27)$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow w^T \varphi(x_i) + b + e_i - y_i = 0 \quad (2.28)$$

Dengan eliminasi  $e$  dan  $w$ , didapatkan persamaan linier sebagai berikut:


$$\begin{bmatrix} 0 & 1_v^T \\ 1_v & \Omega + \frac{1}{C} J \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (2.29)$$

Dimana  $y = [y_1, \dots, y_l]$ ,  $\mathbf{1}_v = [1, \dots, 1]$ ,  $\alpha = [\alpha_1, \dots, \alpha_l]$  dan  $\Omega_{kj} = \varphi(\mathbf{x}_k) \varphi(\mathbf{x}_j)$   $j=1, \dots, l$

Model LS-SVR untuk estimasi fungsi adalah:

$$F(x) = \sum_{i=1}^N \alpha_i K(x_i x_j) + b \quad (2.30)$$

Gambar 2.13 menampilkan bagaimana pemodelan data menggunakan metode Least square support vector regression sebagai berikut:



Gambar 2. 13 Alur Pemodelan Least square support vector regression ( Sumber:Deo & Samui, 2017)


Dengan menggunakan *output* dari nilai prediksi, maka nilai residual dihitung berdasarkan rumus berikut:

$$\text{Residual} = \text{Data aktual (y)} - \text{Data prediksi (\hat{y})} \quad (2.31)$$

## 2.11 Penelitian Terdahulu Tentang *Residual Control Chart*


Telah dilakukan banyak penelitian untuk mengatasi adanya korelasi pada proses produksi termasuk didalamnya tentang *residual control chart* yang merupakan perkembangan diagram kontrol tradisional yang tidak dapat mengakomodir adanya autokorelasi. Penelitian yang dilakukan oleh Kandanand (2014) mengusulkan diagram kontrol yang digunakan untuk memahami karakteristik masing-masing diagram kontrol di bawah situasi autokorelasi. Untuk setiap percobaan, variabel tetap kategoris adalah jenis diagram kontrol (MR dan EWMA grafik) yang digunakan untuk memantau proses dengan persamaan ARIMA (parameter: AR dan parameter: MA). Penelitian lain oleh Shao dan Lin (2013) menggunakan model *fitting*, model AR (1) yang dipakai dan diagram kontrol *residual* dapat memberikan hasil yang lebih baik daripada

diagram kontrol tradisional Shewhart dan EWMA. Yu *et al.* (2015) meneliti *neural network* BP (*Back Propagation*) yang memiliki kecepatan yang cepat pada perhitungan dan fungsi nonlinear yang kuat dengan kemampuan pendekatan dan kemampuan generalisasi kuat yang digunakan untuk meramalkan *output* proses, dan kemudian menghitung *residual*. Membuat diagram kontrol nilai aktual dan nilai prediksi dari  $\bar{x}$ -MR dari sisa, di mana hasilnya menunjukkan bahwa nilai *Moving Range* dan nilai sisa berada dalam garis diagram kontrol. Du dan Lv (2013) menggunakan minimal jarak *Euclidean* (MED) berbasis diagram kontrol yang dikembangkan sebagai alat untuk pemantauan proses autokorelasi. SVR digunakan untuk memprediksi nilai-nilai variabel dalam *time series*. Dengan menggunakan MED, kesalahan kuantisasi dihitung untuk mengukur tingkat penyimpangan proses saat ini dengan kondisi proses terkontrol. Hasil simulasi menunjukkan bahwa grafik MED menunjukkan peningkatan kinerja, yang melebihi beberapa grafik berdasarkan statistik dan skema kontrol berbasis *neural network* untuk pergeseran kecil dalam proses berautokorelasi. Selain itu, Salehi *et al.* (2012) menggunakan diagram kontrol pada data multivariat. Teknik yang digunakan untuk kasus seperti ini adalah prosedur SPC multivariat (MSPC). Penelitian ini menyajikan model modular untuk analisis *on-line* sinyal di luar kontrol dalam proses multivariat. Data *training* sangat penting dalam penggunaan *neural neural* (NN), yang menentukan kualitas kinerja NN. Dalam penelitian ini, simulasi Monte-Carlo digunakan. Korelasi antara *output* aktual dan *output* yang dihasilkan oleh SVM mengungkapkan bahwa output dari model terlatih sangat berkorelasi kuat dengan output sebenarnya untuk setiap karakteristik kualitas. Sedangkan Pan *et al.* (2016) menggunakan diagram kontrol *residual* EWMA dan CUSUM *multistage* untuk dapat mengatasi pengawasan kualitas sistem *multistage* karena memiliki keuntungan dapat mengenali penyebab grafik tidak terkendali. Model sisa EWMA dan diagram kontrol CUSUM *multistage* yang diusulkan didasarkan pada model AR (1), dapat digunakan untuk model *time series* lainnya, seperti ARMA (p, q). Hasil penelitian dapat memberikan alternatif yang lebih baik untuk mendeteksi proses perubahan dan berfungsi sebagai pedoman yang berguna untuk praktisi kualitas saat memantau dan mengendalikan kualitas proses untuk sistem *multistage* dengan data berautokorelasi. Berdasarkan penelitian- penelitian tersebut didapatkan alur metode yang telah digunakan untuk membuat model guna mengatasi autokorelasi pada data sehingga data yang diplotkan pada diagram kontrol tidak berautokorelasi lagi. Gambar 2.14 menunjukkan metode yang telah digunakan dalam pembentukan diagram kontrol *residual* sebagai berikut :



Gambar 2. 14 Pengembangan Pemodelan Diagram Kontrol Residual

Gambar 2.15 menampilkan ringkasan dari pengembangan metode yang digunakan penelitian- penelitian sebelumnya untuk mengilangkan autokorelasi pada data yang akan diplotkan pada diagram kontrol:



Gambar 2. 15 Pengembangan Metode Yang Digunakan Untuk Pemodelan



Tabel 2. 2 Ringkasan Jurnal Terdahulu

No	Judul Jurnal	Penulis	Metode	Tujuan	Hasil
1	Use of control charts with regression analysis for autocorrelated data in the context of logistic financial budgeting (2017)	Jorge Pérez-Rave, Leandro Muñoz-Giraldo, Juan Carlos Correa-Morales	Analisis regresi linier berganda digunakan untuk memodelkan variabel keuangan	Untuk mengetahui apakah penggunaan diagram kontrol dengan analisis regresi adalah cara efektif untuk mengevaluasi permintaan anggaran keuangan (data autokorelasi) di sektor transportasi logistik	Hasilnya menunjukkan bahwa diagram kontrol individu 2.7-sigma baik dalam penelitian ini
2	Support vector regression based residual control charts (2010)	Walid Gani, Hassen Taleb and Mohamed Limam	Support vector regression (SVR) digunakan untuk membuat grafik kontrol residu yang kuat yang disebut SVR-chart.	Membandingkan kinerja metode Ordinary least square (OLS), Partial least square (PLS) dan Support vector regression (SVR) dalam residual control chart.	Metode SVR memberikan hasil yang kompetitif dibandingkan dengan metode OLS dan PLS. Evaluasi kinerja grafik SVR berdasarkan rata-rata panjang run (ARL) menunjukkan bahwa grafik SVR memiliki perilaku ARL terbaik dibandingkan dengan grafik kontrol residu lainnya
3	Guidelines for Applying Statistical Quality Control Method to Monitor Autocorrelated Process (2014)	Karin Kandananond	Metode yang diusulkan adalah <i>Autoregressive Integrated Moving Average</i> , ARIMA (1, 0, 1) dan ARIMA (0, 1, 1) yang dimanfaatkan untuk mengkarakterisasi proses stasioner dan non-stasioner.	Untuk menilai kinerja diagram kontrol menggunakan metode yang berbeda dan untuk mengoptimalkan diagram kontrol untuk proses yang berautokorelasi	Hasil percobaan menunjukkan bahwa grafik EWMA adalah diagram kontrol yang paling sesuai untuk memantau pengamatan yang berautokorelasi.

No	Judul Jurnal	Penulis	Metode	Tujuan	Hasil
4	Self Related Procces <i>Residual</i> Control Chart based Neural Network (2015)	Janli Yu, Yang Han, Manxiang Miao, Hongqi Huang	Membentuk diagram kontrol <i>residual</i> dari proses yang berautokorelasi. <i>Neural Network</i> digunakan untuk memprediksi nilai sisa untuk menghilangkan korelasi <i>time series</i> selanjutnya diterapkan diagram kontrol kualitas statistik untuk proses yang berautokorelasi.	Mengusulkan jenis <i>residual control chart</i> untuk proses yang berautokorelasi yang didasarkan pada <i>Neural Network</i> menggunakan <i>Back Propagation Neural Network</i> untuk membentuk model prediksi seri waktu dari proses yang berautokorelasi	<i>BP Neural network</i> memiliki kemampuan pendekatan yang kuat dan kemampuan menyamaratakan fungsi nonlinier. Menggunakan <i>BP neural network</i> untuk membentuk prediksi secara akurat proses yang berautokorelasi.
5	Multioutput LS SVR based residual MCUSUM control chart for autocorrelated process (2016)	Changha Hwang	Mengusulkan <i>multioutput Least square support vector regression</i> dan menerapkannya untuk membuat diagram kontrol kumulatif <i>CUSUM</i> residual untuk mendeteksi perubahan dalam vektor rata-rata proses.	Menggunakan <i>multioutput least squares support vector regression</i> dan menggunakannya untuk membangun diagram kontrol residual.	Studi numerik menunjukkan diagram kontrol berdasarkan <i>multioutput Least square support vector regression</i> memberikan hasil yang lebih memuaskan dalam mendeteksi pergeseran kecil dalam rata-rata proses.
6	Residual Control Chart for Monitoring Pediatrics Hospital Admission Performances (2015)	Nor Hasliza Mat Desa, Abdul Aziz Jemain dan Maznah Mat Kasim	Menggunakan teknik pre-whitening (PW) untuk menangani adanya autokorelasi pada grafik kontrol statistik	Teknik PW diimplementasikan sebagai prosedur alternatif untuk mendapatkan residual yang secara statistik tidak berkorelasi satu sama lain	Hasil penelitian menunjukkan bahwa terdapat pengurangan jumlah sinyal <i>out-of control</i> dalam diagram kontrol residual dibandingkan dengan jumlah sinyal <i>out-of-</i>

No	Judul Jurnal	Penulis	Metode	Tujuan	Hasil
					<i>control</i> diagram control tradisional sebelum penggunaan teknik PW
7	On line detection of mean and variance shift using neural networks and support vector machine in multivariate process (2012)	Mojtaba Salehi , Reza Baradaran Kazemzadeh dan Ali Salmasnia	<i>Artificial Neural Network</i> (ANN), telah banyak digunakan dalam riset lapangan .Penelitian ini menyajikan model modular untuk analisis <i>on-line</i> sinyal di luar kontrol dalam proses multivariat. Selain itu metode <i>Support Vector Machine</i> juga digunakan pada penelitian ini.	Menggunakan Sebuah <i>Support Vector Machine</i> (SVM) - <i>classifier</i> , pergeseran rata-rata dan pergeseran varians dapat dideteksi. Kemudian menggunakan dua <i>Neural Network</i> khusus untuk rata-rata dan varians, dapat didapatkan besarnya pergeseran untuk setiap variabel secara bersamaan.	Melalui evaluasi dan perbandingan, hasil penelitian ini menunjukkan bahwa modular yang diusulkan jauh lebih baik daripada kontrol grafik tradisional yang sesuai. Kontribusi utama dari penelitian ini adalah mengenali pola tidak wajar dan mengklasifikasikan besarnya pergeseran untuk <i>mean</i> dan <i>variens</i> dalam setiap variabel secara bersamaan.
8	Applying <i>Residual</i> Control Charts to Identify the False Alarms in a TFT-LCD Manufacturing Process (2013)	Yuehjen E. Shao dan Yini Lin	Menerapkan AR (1) pada data manufaktur TFT-LCD.	Pada penelitian ini dilakukan studi empiris dari proses manufaktur TFT-LCD yang sangat kompleks untuk mengidentifikasi metode SPC yang paling sesuai. Berdasarkan analisis <i>time series</i> , penelitian ini mengusulkan diagram kontrol <i>residual</i> menggunakan AR (1).	Hasil pendekatan yang diusulkan memberikan hasil yang lebih baik dibandingkan diagram kontrol Shewhart dan kontrol grafik EWMA dan dapat digunakan untuk meningkatkan proses manufaktur TFT-LCD.
9	Minimal Euclidian	Shichang Du dan Jun Lv	<i>Minimal Euclidean Distance</i> (MED)	Mengusulkan menggunakan <i>Support</i>	Hasil analisis menunjukkan bahwa grafik

No	Judul Jurnal	Penulis	Metode	Tujuan	Hasil
	distance chart based on support vector regression for monitoring mean shifts of autocorrelated processes (2013)		digunakan untuk meningkatkan pemantauan pada pergeseran rata-rata proses yang berautokorelasi. Kinerja diagram kontrol MED yang diusulkan dievaluasi berdasarkan rata-rata panjang run (ARL). Simulasi eksperimen dilakukan dan satu kasus industri diilustrasikan untuk memvalidasi efektivitas dari diagram kontrol MED yang dikembangkan.	<i>Vector Regression</i> (SVR) yang digunakan untuk memprediksi nilai-nilai dari variabel dalam <i>time series</i> . Perhitungan <i>Minimal euclidean distance</i> (MED) nilai <i>time series</i> .	kontrol MED yang dikembangkan lebih efektif daripada diagram kontrol lain untuk pergeseran rata-rata kecil dalam proses berautokorelasi, dan dapat digunakan sebagai alat yang menjanjikan untuk SPC.

## 2.12 GAP Penelitian dan Posisi Penelitian

Pada sub bab ini akan dijelaskan mengenai celah penelitian yang dijadikan acuan bagi penulis dalam penelitian ini. Tabel 2.3 merupakan tabel GAP peneltian yang dibagi berdasarkan metode peramalan dan jenis *control chart* yang dikembangkan.

Tabel 2. 3 Gap Penelitian

No	Nama Penulis	Statistika Deskriptif	Metode Forecast					Jenis <i>Control Chart</i>			
			Neural Network	Support Vector Machine	ARIMA	Regresi	Least Square SVR	Residual Control Chart	Individual Control Chart	CUSUM	EWMA
1	Jorge Pérez-Rave, Leandro Muñoz-Giraldo, Juan Carlos Correa-Morales	√				√		√	√	√	√
2	Walid Gani, Hassen Taleb and Mohamed Limam			√				√	√		
3	Karin Kandananond				√			√			√
4	Janli Yu, Yang Han, Manxiang Miao, Hongqi Huang		√					√	√		
5	Changha Hwang						√	√		√	
6	Nor Hasliza Mat Desa, Abdul Aziz Jemain dan Maznah Mat Kasim				√			√	√		

No	Nama Penulis	Statistika Deskriptif	Metode Forecast					Jenis Control Chart			
			Neural Network	Support Vector Machine	ARIMA	Regresi	Least Square SVR	Residual Control Chart	Individual Control Chart	CUSUM	EWMA
7	Mojtaba Salehi , Reza Baradaran Kazemzadeh dan Ali Salmasnia		√	√					√		
8	Yuehjen E. Shao dan Yini Lin				√			√	√		√
9	Shichang Du dan Jun Lv			√	√			√		√	√
10	Penelitian yang akan dilakukan	√		√			√	√	√		

Berdasarkan GAP penelitian, penelitian selanjutnya akan menggunakan diagram kontrol *residual* untuk mengatasi adanya autokorelasi. *Residual* tersebut didapatkan dari model peramalan. Banyak model peramalan yang dapat dipakai untuk mendapatkan *residual* diantaranya *Support Vector Regression* (SVR), Metode ARIMA dan metode Regresi. Metode *Support Vector Regression* banyak digunakan namun fungsi *constrain*-nya berupa petidaksamaan sehingga parameter yang di estimasi menjadi lebih banyak. Model ARIMA mudah digunakan namun kurang bisa mengakomodir adanya *shift* kecil pada rata-rata, selain itu ARIMA juga kurang sesuai untuk data yang tidak linier. Model Regresi mudah dan sangat umum digunakan namun harus memenuhi beberapa asumsi sehingga kurang menggambarkan data secara lengkap. Metode yang di usulkan adalah dengan menggunakan *extention Support vector regression* yaitu *Least square support vector regression* dan *Genetic algorithm support vector regression*. *Least square support vector regression* memiliki konstrain berupa persamaan sehingga akan berdampak pada fungsi *lagrange* yang hanya memiliki satu *lagrange multiplier* dibandingkan dua *lagrange multiplier* pada *Support vector regression*. Hal ini mempengaruhi banyaknya peubah yang harus diestimasi sehingga berakibat pada ketepatan pemodelan dan kecepatan perhitungan. Selanjutnya *residual* dari pemodelan akan dipetakan pada diagram kontrol individual. Metode lain yang di gunakan adalah dengan mengoptimalkan parameter *Support vector regression* yang digunakan oleh Gani et al. (2010) dengan menggunakan Algoritma genetika. Untuk membentuk model SVR secara efisien, parameter SVR harus diatur dengan hati-hati. Pengaturan parameter yang berbeda dapat menyebabkan perbedaan signifikan dalam kinerja pemodelan. Karena itu, memilih parameter adalah langkah penting dalam SVR. Pemilihan Algoritma genetika (GA) dibandingkan dengan teknik optimasi lain adalah karena GA punya operator *elitisme* yang dapat menyimpan solusi terbaik sehingga tetap muncul di dalam populasi di iterasi berikutnya. Selain itu pencarian solusi terbaik berdasarkan kandidat set yang luas sehingga hasil cenderung menuju ke global optimum (Santosa & Willy, 2011). Oleh karena itu, dalam penelitian ini, diusulkan algoritma genetika untuk menentukan parameter SVR yang mengoptimalkan semua parameter SVR secara bersamaan dari data *training*, sehingga didapatkan model yang memiliki keakuratan tinggi.


## BAB 3

### METODOLOGI PENELITIAN


Pada bab ini diberikan gambaran kerangka berpikir dalam pelaksanaan penelitian ini yang terdiri dari beberapa tahapan yang saling berurutan. Tahapan – tahapan yang dilakukan pada penelitian ini dapat dilihat pada Gambar 3.1.

#### 3.1 Diagram Alir


Diagram alir untuk setiap tahapan penelitian disajikan pada Gambar 3.1.







Gambar 3. 1 *Flowchart* Penelitian



Gambar 3. 2 Alur Pemodelan Data Menggunakan GA-SVR

### **3.2 Perumusan Masalah**

Tahap Perumusan Masalah adalah tahap awal penelitian. Permasalahan pada penelitian ini muncul dilatar belakang oleh ketidaksesuaian hasil pengamatan dan hasil diagram kontrol yang disebabkan oleh adanya autokorelasi. Pemilihan model regresi yang digunakan untuk menghilangkan autokorelasi pada penelitian Pérez-Rave et al. (2017) masih menghasilkan diagram kontrol *residual* yang terletak pada batas kendali sehingga menyebabkan kesimpulan yang keliru tentang data. Selain itu untuk menegaskan kebaikan dari metode pemodelan yang diusulkan maka digunakan data dari penelitian Gani et al., (2010). Maka dari itu digunakan model yang lebih tepat agar diagram kontrol dan keadaan data sebenarnya tidak menghasilkan kesimpulan yang berbeda.

### **3.3 Pengujian Normalitas Data**

Pengujian kenormalan data bertujuan untuk mengetahui distribusi dari data. Salah satu syarat untuk membangun diagram kontrol dan melakukan pemodelan terhadap data pengamatan adalah memenuhi asumsi bahwa data berdistribusi normal, maka dari itu diperlukan pengujian terhadap kenormalan data dengan menggunakan uji Shapiro wilk. Apabila data yang diperoleh ternyata tidak memenuhi asumsi normal maka dapat dilakukan transformasi data agar data menjadi normal. Beberapa metode transformasi yang dapat digunakan seperti *Square Roots Transformation* dan *Logit Transformation*. Pengujian dilakukan terhadap data penelitian Gani et al., (2010) karena pada penelitian Pérez-Rave et al. (2017) telah dilakukan uji normalitas.

### **3.4 Pengujian Autokorelasi**

Pengujian autokorelasi digunakan untuk melihat apakah ada hubungan serial antar data pengamatan. Jika terdapat korelasi atau hubungan maka diagram kontrol Shewhart tidak dapat lagi digunakan karena akan menghasilkan kesimpulan yang salah. Maka dari itu jika autokorelasi terjadi maka dilakukan pemodelan data terlebih dahulu, yang selanjutnya residual dari pemodelan akan digunakan untuk mewakili data pada diagram kontrol. Pengujian dilakukan terhadap data penelitian Gani et al., (2010) karena pada penelitian Pérez-Rave et al. (2017) telah dilakukan uji autokorelasi.

### **3.5 Perbandingan Metode Pemodelan**

Pada tahap ini pemodelan data berdasarkan metode *Least square support vector regression* dan *Genetic algorithm support vector regression* yang telah dilakukan di bandingkan dengan metode pemodelan yang dipakai pada penelitian Pérez-Rave et al. (2017) yang menggunakan metode Regresi dan Gani et al., (2010) yang memakai metode *support vector regression*. Kriteria perbandingan metode yang lebih baik adalah dengan melihat nilai *Root Mean Square Error* (RMSE). Jika didapatkan nilai RMSE yang lebih kecil maka dapat dikatakan bahwa metode pemodelan lebih baik dibandingkan dengan metode Regresi dan *support vector regression*.

### **3.6 Residual Control Chart Berdasarkan Least Square Support Vector Regression dan Genetic Algorithm Support Vector Regression**

Salah satu metode pemodelan yang dapat digunakan untuk membuat *residual control chart* adalah *least square support vector regression* dan *Genetic algorithm support vector regression*. Pada penelitian ini dilakukan pemodelan data menggunakan metode *least square support vector regression* serta *Genetic algorithm support vector regression* dan selanjutnya *residual* diplot dalam *individual control chart*.

### **3.7 Analisa dan Pembahasan**

Pada tahap ini dilakukan analisis terhadap langkah dan metode yang telah dilakukan. Hal ini meliputi analisa statistika deskriptif, pengujian kenormalan data, pengujian autokorelasi data, pemodelan menggunakan *Least square support vector regression* dan *Genetic algorithm support vector regression*, pemetaan *residual* pemodelan terhadap *individual control chart*.

### **3.8 Kesimpulan dan Saran**

Pada tahap ini dilakukan penarikan kesimpulan dari penelitian yang telah dilakukan dan memberikan saran baik itu untuk perusahaan maupun untuk penelitian selanjutnya.

**(Halaman ini sengaja dikosongkan)**

## BAB IV

### PENGOLAHAN DATA

#### 4.1. Data Penelitian

Data yang digunakan pada penelitian ini adalah data yang berasal dari penelitian Pérez-Rave et al. (2017) yang berjudul *Use of control charts with regression analysis for autocorrelated data in the context of logistic financial budgeting*. Data didapatkan dari sebuah perusahaan di Kolombia. Peubah terikat yaitu biaya bahan bakar (*c.combu.ret*). Penggunaan data *financial* dilatarbelakangi karena sebuah departemen pada suatu perusahaan dapat meminta jumlah anggaran yang lebih besar atau lebih kecil dari anggaran sebenarnya. Perbedaan ini cenderung diselesaikan berdasarkan pengalaman masa lalu, yaitu berdasarkan rata-rata data historis keuangan. Karena itu, perlu untuk memantau, memahami dan mengendalikan variabilitas proses keuangan, agar tidak mempengaruhi operasi normal perusahaan. Data dalam penelitian ini dikumpulkan berdasarkan urutan waktu sehingga disebut data *time series*. Data kedua adalah data yang digunakan dalam penelitian Gani et al. (2010) yang berjudul *Support vector regression based residual control charts*. Data dalam penelitian ini diambil dari Montgomery (2013) halaman 514 tabel 11.5. Data penelitian Pérez-Rave et al. (2017) merupakan data *timeseries* yang terdiri dari tiga variabel, peubah terikat yang dimasukkan adalah biaya bahan bakar kendaraan (Y) dengan peubah bebas banyaknya barang yang diangkut (X1) dan harga satu galon bahan bakar (X2) yang ditampilkan pada Tabel 4.1. Data data *training* ditampilkan pada Tabel 4.2 terdiri dari 27 data *in control* dan data *testing* ditampilkan pada Tabel 4.3 terdiri dari 9 data *out of control* yang digunakan untuk memvalidasi diagram kontrol yang didapatkan dari data *training*. Selanjutnya set data ini disebut data autokorelasi dan cacat (DAC) yang ditampilkan sebagai berikut :

Tabel 4.1 Peubah dari Anggaran Keuangan Logistik

Model	Tipe Peubah	Notasi	Keterangan
Fungsi	Peubah Terikat	<i>c.combu.ret</i>	biaya bahan bakar kendaraan (Y)
	Peubah Bebas	<i>uds</i>	banyaknya barang yang diangkut (X1)
	Peubah Bebas	<i>precio.comb</i>	harga satu galon bahan bakar (X2)

Tabel 4.2 Data *Training* DAC

Ytrain	c.combu.ret	Xtrain	precio.comb	uds
	3,49959		88,6256	6,093013
	4,077211		90,25729	6,408108
	3,573942		90,60533	6,519663
	4,270376		89,41948	7,933386
	3,788551		87,72288	7,558306
	3,336124		88,16016	7,05258
	3,891426		89,05314	7,53374
	3,929965		89,11097	7,781537
	4,248589		88,93991	8,158611
	5,069076		89,00376	9,150754
	5,430712		89,10807	9,901945
	5,519504		89,0966	9,29985
	4,444971		89,8403	7,215381
	5,106543		90,0437	7,897146
	5,076515		90,21024	8,351777
	5,252643		91,14297	8,534804
	6,860134		91,15792	8,908967
	5,093738		91,16012	7,57001
	5,727841		91,05095	8,783308
	6,31941		91,0047	8,413155
	6,585889		90,70222	9,216735
	6,184382		91,53435	9,421793
	6,201319		89,41508	9,600593
	3,869999		90,47692	7,173869
	4,90544		90,12436	8,010898
	5,358992		90,00545	8,638943
	4,809183		90,20224	8,220763

Tabel 4.3 Data *Testing* DAC

c.combu.ret	precio.comb	uds
2,880131	91,53585	6,4885
3,02107	92,46036	6,887237
2,700987	92,37077	6,526485
1,94584	92,36729	7,03607
3,136504	91,91344	6,526132
3,907488	90,39892	6,798976
3,722022	92,15555	7,472415
3,669491	92,96415	7,43883
3,596199	94,03364	7,853144

(Sumber: Pérez-Rave et al., 2017)

Data kedua adalah data yang digunakan pada penelitian Gani et al. (2010) yang berjudul *Support Vector Regression Based Residual Control Chart* dimana data bukan merupakan data *time series* yang memiliki satu peubah terikat (Y1) dan 9 peubah bebas (X1, X2, ..., X9). Data terdiri dari 40 data *in control* yang dibagi menjadi 30 data *training* dan 10 data *testing*. Selanjutnya set data ini disebut data autokorelasi (DA) yang disajikan pada Tabel 4.4 sebagai berikut:

Tabel 4.4 Data DA

Y1	x1	x2	x3	x4	x5	x6	x7	x8	x9
951,5	12,78	0,15	91	56	1,54	7,38	1,75	5,89	1,11
952,2	14,97	0,1	90	49	1,54	7,14	1,71	5,91	1,109
952,3	15,43	0,07	90	41	1,47	7,33	1,64	5,92	1,104
951,8	14,95	0,12	89	43	1,54	7,21	1,93	5,71	1,103
952,3	16,17	0,1	83	42	1,67	7,23	1,86	5,63	1,103
952,2	17,25	0,07	84	54	1,49	7,15	1,68	5,8	1,099
950,2	16,57	0,12	89	61	1,64	7,23	1,82	5,88	1,096
950,5	19,31	0,08	99	60	1,46	7,74	1,69	6,13	1,092
950,6	18,75	0,04	99	52	1,89	7,57	2,02	6,27	1,084
949,8	16,99	0,09	98	57	1,66	7,51	1,82	6,38	1,086
951,2	18,2	0,13	98	49	1,66	7,27	1,92	6,3	1,089
950,6	16,2	0,16	97	52	2,16	7,21	2,34	6,07	1,089
948,9	14,72	0,12	82	61	1,49	7,33	1,72	6,01	1,092
951,7	14,42	0,13	81	63	1,16	7,5	1,5	6,11	1,094



951,5	11,02	0,1	83	56	1,56	7,14	1,73	6,14	1,102
951,3	9,82	0,1	86	53	1,26	7,32	1,54	6,15	1,112
952,9	11,41	0,12	87	49	1,29	7,22	1,57	6,13	1,114
953,9	14,74	0,1	81	42	1,55	7,17	1,77	6,28	1,114
953,3	14,5	0,08	84	53	1,57	7,23	1,69	6,28	1,109
952,6	14,71	0,09	89	46	1,45	7,23	1,67	6,12	1,108
952,3	15,26	0,13	91	47	1,74	7,28	1,98	6,19	1,105
952,6	17,3	0,12	95	47	1,57	7,18	1,86	6,06	1,098
952,9	17,62	0,06	95	42	2,05	7,15	2,14	6,15	1,096
953,9	18,21	0,06	93	41	1,46	7,28	1,61	6,11	1,096
954,2	14,38	0,1	90	46	1,42	7,29	1,73	6,13	1,1
951,9	12,13	0,14	87	50	1,76	7,21	1,9	6,31	1,112
952,3	12,72	0,1	90	47	1,52	7,25	1,79	6,25	1,112
953,7	17,42	0,1	89	51	1,33	7,38	1,51	6,01	1,111
954,7	17,63	0,11	87	45	1,51	7,42	1,68	6,11	1,103
954,6	16,17	0,05	83	57	1,41	7,35	1,62	6,14	1,105
954,8	16,88	0,16	86	58	2,1	7,15	2,28	6,42	1,105
954,4	13,87	0,16	85	46	2,1	7,11	2,16	6,44	1,106
955	14,56	0,05	84	41	1,34	7,14	1,51	6,24	1,113
956,5	15,35	0,12	83	40	1,52	7,08	1,81	6	1,114
955,3	15,91	0,12	81	45	1,76	7,26	1,9	6,07	1,116
954,2	14,32	0,11	85	47	1,58	7,15	1,72	6,02	1,113
955,4	15,43	0,13	86	43	1,46	7,15	1,73	6,11	1,115
953,8	14,47	0,08	85	54	1,62	7,1	1,78	6,15	1,118
953,2	14,74	0,07	84	52	1,47	7,24	1,66	5,89	1,112
954,2	16,28	0,13	86	49	1,72	7,05	1,89	5,91	1,109

(Sumber: Gani et al., 2010)

#### 4.2. Statistika Deskriptif

Statistika deskriptif digunakan untuk mengetahui pusat dan penyebaran dari data. Pusat data dapat diketahui melalui rata-rata, nilai tengah dan modus sedangkan penyebaran dapat dilihat melalui variansi, standar deviasi, dan range. Tabel 4.5 menampilkan statistika deskriptif DAC, sedangkan Tabel 4.6 menampilkan statistik deskriptif dari DA sebagai berikut:

Tabel 4.5 Statistik Deskriptif DAC


Variable	Mean	SE Mean	StDev	Minimum	Q1	Median	Q3	Maximum
c.combu.ret	4,473	0,198	1,187	1,946	3,615	4,259	5,332	6,860
precio.comb	90,483	0,237	1,425	87,723	89,187	90,328	91,441	94,034
uds	7,844	0,170	1,020	6,093	7,040	7,817	8,613	9,902

Tabel 4.6 Statistik Deskriptif DA


Variable	Mean	SE Mean	StDev	Minimum	Q1	Median	Q3	Maximum
Y1	952,78	0,271	1,71	948,90	951,55	952,60	954,20	956,50
x1	15,339	0,333	2,107	9,820	14,432	15,305	16,962	19,310
x2	0,10425	0,00491	0,03104	0,04000	0,08000	0,10000	0,12750	0,16000
x3	88,125	0,831	5,254	81,000	84,000	87,000	90,750	99,000
x4	49,67	1,00	6,35	40,00	45,00	49,00	54,00	63,00
x5	1,5872	0,0357	0,2256	1,1600	1,4600	1,5400	1,6675	2,1600
x6	7,2582	0,0224	0,1414	7,0500	7,1500	7,2300	7,3275	7,7400
x7	1,7907	0,0312	0,1970	1,5000	1,6725	1,7400	1,8975	2,3400
x8	6,0955	0,0286	0,1810	5,6300	6,0025	6,1150	6,2275	6,4400
x9	1,1042	0,00143	0,00906	1,0840	1,0965	1,1050	1,1120	1,1180

### 4.3. Uji Normalitas


Salah satu asumsi diagram kontrol adalah bahwa data mengikuti distribusi normal. Untuk mengetahui apakah data telah mengikuti distribusi normal atau tidak maka digunakan uji normalitas. Uji normalitas dalam penelitian ini menggunakan histogram dan Q-Q plot untuk menguji normalitas dari data. Hasil uji normalitas dengan menggunakan histogram dan Q-Q plot dengan nilai uji Shapiro Wilks untuk peubah DAC ditampilkan pada Gambar 4.1 dan Gambar 4.2, sedangkan histogram dan Q-Q plot dengan nilai uji Shapiro Wilks untuk DA ditampilkan pada Gambar 4.3 dan Gambar 4.4 sebagai berikut:




Gambar 4.1 Histogram DAC



Gambar 4.2 QQ Plot DAC




Gambar 4.3 Histogram DA




Gambar 4.4 QQ Plot DA

#### 4.4. Diagram Kontrol Residual Berdasarkan Model Regresi Berganda Dan Support Vector Regression


Data aktual dalam penelitian Pérez-Rave et al. (2017) dan Gani et al. (2010) menampilkan 7 titik data yang berada di luar batas kontrol seperti yang ditampilkan pada Lampiran 1.a dan Lampiran 1.b, sehingga dapat disimpulkan bahwa data tidak terkendali secara statistik. Hal ini disebabkan karena adanya autokorelasi pada kedua data tersebut seperti yang ditampilkan pada Lampiran 2.a dimana *Lag* pertama dari data signifikan yang ditunjukkan dengan nilai sig. sebesar 0.001. Pada subbab ini ditampilkan *plotting* data *residual* dari penelitian sebelumnya yang dilakukan oleh Pérez-Rave et al. (2017) dan Gani et al. (2010) dengan maksud agar dapat melihat bahwa pada model yang digunakan sebelumnya dengan model yang dipakai pada penelitian ini. Gambar 4.5 menampilkan diagram kontrol individual dari *residual* regresi pada data *training* DAC, Gambar 4.6 menampilkan diagram kontrol individual dari *residual* regresi pada data *testing* DAC dan Gambar 4.7 memperlihatkan diagram kontrol individual DA sebagai berikut:



Gambar 4.5 Individual Control Chart Data *Training* DAC berdasarkan Model Regresi




Gambar 4.6 Individual Control Chart Data *Testing* DAC berdasarkan Model Regresi




Gambar 4.7 Individual Control Chart DA berdasarkan Model Support Vector Regression

#### 4.5 Least Square Support Vector Regression dan Genetic Algoritma Support Vector Regression


Tahapan pertama dalam membuat diagram kontrol *residual* berdasarkan model *Least square support vector regression* adalah memodelkan data pengamatan. Hasil pemodelan data menggunakan metode *Least square support vector regression* dan *Genetic algorithm support vector regression* dibandingkan dengan data aktual untuk melihat seberapa dekat hasil prediksi yang ditampilkan pada Gambar 4.8, Gambar 4.9, Gambar 4.10 dan Gambar 4.11 sebagai berikut:




Gambar 4.8 Plot Data *Testing* DAC dengan Data Hasil Pemodelan LSSVR



Gambar 4.9 Plot Data *Testing* DAC dengan Data Hasil Pemodelan GASVR



Gambar 4.10 Plot DA dengan Data Hasil Pemodelan LSSVR



Gambar 4.11 Plot DA dengan Data Hasil Pemodelan GASVR

Tabel 4.7 Perbandingan Metode Pemodelan DAC

Metode	SSE	MSE	RMSE
Regresi	40,15330	4,461480	2,112220
LS-SVR	25,16083	2,795648	1,672019
GA-SVR	21,742911	2,415879	1,554310




Tabel 4.8 Perbandingan Metode Pemodelan DA


Metode	SSE	MSE	RMSE
Regresi	16,28064	1,6281	1,2760
SVR	12,0099	1,2001	1,0959
LS-SVR	11,106	1,0539	1,0266
GA-SVR	2,47753	0,3094	0,5565

#### 4.6 Diagram Kontrol Residual Berdasarkan *Least Square Support Vector Regression* dan *Genetic Algorithm Support Vector Regression*


Diagram kontrol *residual* didapatkan dari data residual dari selisih antara data aktual dikurangi dengan data hasil pemodelan menggunakan metode *Least square support vector regression* dan *Genetic algorithm support vector regression*. Selanjutnya residual diplotkan pada diagram kontrol individual. Plot data residual berdasarkan *Least square support vector regression* ditampilkan pada Gambar 4.12 dan Gambar 4.13, sedangkan Gambar 4.14 dan Gambar 4.15 menampilkan plot residual dari model *Genetic Algorithm Support Vector Regression* sebagai berikut:




Gambar 4.12 Diagram Kontrol *Residual Data Testing* DAC Berdasarkan Model *Least square support vector regression*



Gambar 4.13 Diagram Kontrol *Residual* DA Berdasarkan Model Least Square Support Vector Regression



Gambar 4.14 Diagram Kontrol *Residual* Data Testing DAC Berdasarkan Model Genetic Algorithm Support Vector Regression



Gambar 4.15 Diagram Kontrol *Residual* DA Berdasarkan Model Genetic Algorithm Support Vector Regression

## BAB 5

### ANALISIS DAN INTERPRETASI HASIL

Bab analisis dan interpretasi hasil berisi tentang penjelasan dari bab 4 yang memuat hasil *output* dan juga perbaikan dari metode pemodelan yang dilakukan pada penelitian sebelumnya.

#### 5.1 Statistik Deskriptif

Langkah pertama analisis data adalah menghitung statistik deskriptif. Statistik deskriptif adalah statistik yang berfungsi untuk mendeskripsikan atau memberi gambaran terhadap objek yang diteliti melalui data sampel atau populasi sebagaimana adanya, tanpa melakukan analisis dan membuat kesimpulan yang berlaku untuk umum. Statistik deskriptif mencakup tentang penyajian data, ukuran pemusatan data dan ukuran penyebaran data. Dalam penelitian ini statistik deskriptif digunakan untuk melihat pola penyebaran data sehingga akan dapat dilihat bagaimana bentuk distribusi data. Statistik yang ditampilkan adalah *mean*, SE *mean*, standar deviasi, minimum, kuartil 1 (Q1), median, kuartil 3 (Q3) dan maksimum. *Mean* menunjukkan pusat dari nilai data. Dari hasil perhitungan dapat dilihat *mean* peubah terikat dari DAC adalah sebesar 4,473 dan *mean* untuk peubah terikat dari DA adalah sebesar 952,78. *Standart deviasi* digunakan untuk melihat homogenitas dari data. Sedangkan *range* yang merupakan selisih antara nilai terbesar dan terkecil merupakan ukuran yang paling sederhana dari ukuran penyebaran data. Berdasarkan dari perhitungan, *range* dari peubah terikat DAC adalah 4,914 yang berarti nilai ini relatif kecil, sehingga data akan mengumpul disekitar nilai *mean*. *Range* dari peubah terikat DA adalah sebesar 5,44 yang berarti nilai ini relatif kecil, sehingga data akan mengumpul disekitar nilai *mean*.

#### 5.2 Uji Normalitas

Asumsi dasar dalam penggunaan diagram kontrol adalah data proses saat terkontrol mengikuti distribusi normal dengan rata-rata  $\mu$  dan standar deviasi  $\sigma$ . Ada banyak jenis distribusi data baik itu untuk data diskrit maupun kontinyu. Untuk menguji normalitas data dapat menggunakan cara visual atau menggunakan uji statistik. Salah satu cara untuk melakukan uji normalitas secara visual adalah menggunakan Histogram. Jika pola data pada Histogram membentuk pola yang hampir sama dengan pola kurva normal maka dapat

disimpulkan data mengikuti distribusi normal. Gambar 4.1 menunjukkan pola Histogram DAC dan Gambar 4.3 yang menunjukkan pola Histogram DA yang memiliki pola hampir sama dengan pola kurva normal. Secara visual dapat disimpulkan ketiga set data tersebut mengikuti distribusi normal.

Uji normalitas pada penelitian ini juga dilakukan dengan menggunakan quantile-quantile (QQ) *plot* berdasarkan uji statistik Shapiro Wilks. Gambar 4.2 menunjukkan QQ *plot* DAC. Pada Gambar 4.2 juga menampilkan nilai statistik uji Shapiro Wilks, berdasarkan gambar dapat diketahui bahwa nilai Shapiro Wilks data adalah 0,985 dan  $p\_value$  sebesar  $>0,100$ . Sesuai dengan kriteria pengujian statistik, jika nilai Shapiro Wilks data dan  $p\_value$  pengujian statistik lebih besar dari nilai kritis yang ditetapkan peneliti maka dapat disimpulkan bahwa data mengikuti distribusi normal. Karena nilai  $p\_value$  yang dihasilkan lebih besar dari nilai kritis yang ditetapkan sebesar 0,05 maka DAC berdistribusi normal. Pada Gambar 4.4 menunjukkan QQ *plot* DA. Pada Gambar 4.4 juga menampilkan nilai statistik uji Shapiro Wilks, berdasarkan gambar dapat diketahui bahwa nilai Shapiro Wilks data adalah 0,996 dan  $p\_value$  sebesar  $>0,100$ . Karena nilai  $p\_value$  yang dihasilkan lebih besar dari nilai kritis yang ditetapkan sebesar 0,05 maka data berdistribusi normal. Setelah diketahui bahwa DAC dan DA berdistribusi normal maka dapat dilakukan pengontrolan kualitas menggunakan diagram kontrol.

### **5.3 Diagram Kontrol Residual Berdasarkan Model Regresi dan Support Vector Regression**

Residual *control chart* pada penelitian Pérez-Rave et al. (2017) dibuat dengan menggunakan diagram kontrol individual. Gambar 4.5 menunjukkan diagram kontrol individual dari residual data *training* DAC berdasarkan model regresi. Berdasarkan Gambar 4.5, dapat dilihat bahwa ada satu titik yang berada pada garis batas kendali *control chart* yang artinya proses telah terkontrol secara statistik namun satu titik ini harus lebih diperhatikan karena bisa menimbulkan kesimpulan yang berbeda jika jumlah datanya diperbesar. Selanjutnya, Gambar 4.6 menunjukkan individual *control chart* dari residual data *testing* DAC berdasarkan model regresi. Berdasarkan Gambar 4.6, dapat dilihat bahwa ada 8 dari 9 titik data yang berada pada diluar batas kendali *control chart* dimana 9 data ini adalah data kurang baik yang digunakan untuk menguji apakah model yang telah didapatkan sudah baik atau belum. Selanjutnya, Residual *control chart* pada penelitian Gani et al. (2010) juga dibuat dengan

menggunakan diagram kontrol individual. Gambar 4.7 menunjukkan diagram kontrol individual dari residual data berdasarkan model *Support vector regression*. Berdasarkan Gambar 4.7, dapat dilihat bahwa ada satu titik yang berada diluar garis batas kendali *control chart* yang artinya proses telah terkontrol secara statistik namun satu titik ini harus lebih diperhatikan karena bisa menimbulkan kesimpulan yang berbeda jika jumlah datanya diperbesar. Dari penelitian yang dilakukan oleh Pérez-Rave et al. (2017) dan Gani et al. (2010) dapat dilihat bahwa terdapat data yang masih berada pada garis batas diagram kontrol, hal ini dipengaruhi oleh keakuratan model yang digunakan. Semakin akurat model yang digunakan maka diagram kontrol yang dihasilkan akan semakin baik.

#### **5.4 Least Square Support Vector Regression dan Genetic Algorithm Support Vector Regression**

Tahapan awal dari pembentukan model *Least square support vector regression* dan *Genetic Algorithm Support Vector Regression* adalah menghitung parameter model. Setelah parameter diketahui maka di buat modelnya untuk melakukan pemodelan pada DAC dan DA. Untuk mengevaluasi kebaikan dari model digunakan *Root Mean Square Error* (RMSE) dimana semakin kecil nilai RMSE maka model yang dihasilkan semakin baik yang akan menghasilkan data hasil pemodelan yang hampir sama dengan data aktual. Nilai RMSE akan mempengaruhi kinerja diagram kontrol. Dengan nilai RMSE yang semakin kecil maka *residual* dari pemodelan akan semakin kecil sehingga penyebaran data dalam diagram kontrol tidak jauh dari nilai tengahnya. Titik- titik data yang menyebar di sekitar nilai tengah akan menyebabkan tidak ada data yang keluar dari batas diagram kontrol sehingga akan menghasilkan diagram kontrol yang tepat.

Tabel 4.7 menampilkan perbandingan RMSE antara model regresi, model *Least square support vector regression* dan *Genetic algorithm support vector regression* untuk DAC, sedangkan Tabel 4.8 menampilkan perbandingan RMSE antara model regresi, *Support vector regression*, *Least square support vector regression* dan *Genetic algorithm support vector regression* untuk DA. Dapat dilihat pada Tabel 4.7 nilai RMSE dari model regresi untuk DAC adalah sebesar 2,11222. Sedangkan pada Tabel 4.8 nilai RMSE dari model regresi untuk DA adalah sebesar 1,1296. Hasil pemodelan dari penelitian dengan menggunakan metode *Least square support vector regression* menampilkan nilai RMSE yang lebih kecil daripada

penelitian sebelumnya yang menggunakan metode regresi. Pada Tabel 4.7 dapat dilihat nilai RMSE dari metode *Least square support vector regression* untuk DAC adalah sebesar 1,672019 namun *Genetic algorithm support vector regression* menghasilkan nilai RMSE terkecil yaitu sebesar 1,554310. Pada Tabel 4.8 dapat dilihat nilai RMSE dari model regresi, SVR, LS SVR dan GA SVR. Dari tabel terlihat bahwa nilai RMSE paling kecil adalah berdasarkan model GA-SVR yaitu sebesar 0,5565 dibandingkan dengan regresi sebesar 1,1296, SVR sebesar 1,0959 dan LS-SVR sebesar 1,0266. Berdasarkan nilai RMSE dapat disimpulkan bahwa model yang terbaik adalah model *Genetic Algorithm Support Vector Regression*.

### **5.5 Diagram Kontrol Residual Berdasarkan Model Least Square Support Vector Regression dan Genetic Algorithm Support Vector Regression**

Sebagai pengembangan dari diagram kontrol residual yang telah dilakukan pada penelitian Pérez-Rave et al. (2017) dan Gani et al. (2010), pada penelitian ini digunakan metode *Least square support vector regression* dan *Genetic algorithm support vector regression* dalam pembentukan *control chart* yang juga memakai nilai residual dari peramalan. Tujuan dari residual diagram kontrol berdasarkan *Least square support vector regression* dan *Genetic algorithm support vector regression* adalah untuk mengevaluasi proses pada diagram kontrol residual menggunakan model regresi dan *Support vector regression* agar tingkat ketepatan pemodelan lebih akurat sehingga akan berdampak pada semakin baiknya diagram kontrol.

Gambar 4.12 menunjukkan individual *control chart* berdasarkan residual *Least square support vector regression* dengan menggunakan kernel RBF dari data *testing* DAC. Berdasarkan Gambar 4.12 dapat dilihat bahwa ada 8 titik data dari 9 data yang berada di luar batas kendali. Dapat disimpulkan bahwa diagram kontrol yang dihasilkan berdasarkan model *Least square support vector regression* menghasilkan diagram kontrol yang sesuai dengan keadaan data yang sebenarnya. Gambar 4.13 menampilkan diagram kontrol *residual* dari DA berdasarkan model *Least square support vector regression*. Berdasarkan Gambar 4.13 dapat dilihat bahwa ada 1 titik data berada di luar batas kendali. Gambar 4.14 menunjukkan individual *control chart* berdasarkan residual *Genetic algorithm support vector regression* dengan menggunakan kernel RBF dari DAC. Berdasarkan Gambar 4.14 dapat dilihat bahwa

ada 8 titik data dari 9 data yang berada di luar batas kendali. Dapat disimpulkan bahwa diagram kontrol yang dihasilkan berdasarkan model *Genetic algorithm support vector regression* menghasilkan diagram kontrol yang sesuai dengan keadaan data yang sebenarnya. Gambar 4.15 menampilkan diagram kontrol *residual* dari DA berdasarkan model *Genetic algorithm support vector regression*. Dapat dilihat bahwa diagram kontrol yang dihasilkan lebih baik dibandingkan diagram kontrol yang dihasilkan berdasarkan model *Support vector regression* dikarenakan tidak ada data yang keluar batas kontrol.

Secara keseluruhan, dapat disimpulkan bahwa evaluasi proses menggunakan residual *Least square support vector regression* dengan kernel RBF menunjukkan hasil yang hampir sama dengan residual *control chart* berdasarkan model Regresi. Residual *control chart* berdasarkan model *Least square support vector regression* menghasilkan kesimpulan bahwa DAC sesuai dengan keadaan data yang sebenarnya namun masih ada data yang terletak pada garis batas kendali. Sedangkan, Residual *control chart* berdasarkan model *Genetic algorithm support vector regression* menghasilkan kesimpulan bahwa DAC dan DA terkendali secara statistik. Sehingga dapat disimpulkan bahwa model *Least square support vector regression* dan *Genetic algorithm support vector regression* lebih sesuai untuk mengatasi data yang berautokorelasi dibandingkan dengan model Regresi dan *Support vector regression*.



**(Halaman ini sengaja dikosongkan)**

## BAB 6

### KESIMPULAN DAN SARAN

#### 6.1 Kesimpulan

Berdasarkan hasil evaluasi dengan diagram kontrol menggunakan metode *Least square support vector regression* dan *Genetic algorithm support vector regression*, maka dapat disimpulkan beberapa hal sebagai berikut:

1. Setelah dilakukan *plotting* menggunakan diagram kontrol pada data aktual, didapat kesimpulan bahwa DAC dan DA tidak terkontrol secara statistik. Keadaan ini menghasilkan *error* tipe I dimana produk yang seharusnya baik namun di tolak karena adanya autokorelasi.
2. Berdasarkan uji normalitas data, didapatkan bahwa DAC dan DA mengikuti distribusi normal.
3. Berdasarkan plot data aktual dan residual hasil pemodelan, data hasil prediksi berhimpit mengikuti pola data aktual. Nilai RMSE yang didapatkan untuk DA adalah :
  - Gani (2010)            RMSE = 1,0959
  - LSSVR                RMSE = 1,0266
  - GASVR                RMSE = 0,5565

Nilai RMSE untuk metode *Least square Support vector regression* sebesar 1,0266 yang lebih kecil 7% dibandingkan *Support vector regression* pada penelitian Gani et al. (2010). Sedangkan nilai RMSE untuk metode *Genetic algorithm Support vector regression* sebesar 0,5565 yang lebih kecil 51% dibandingkan metode *support vector regression* pada penelitian Gani et al. (2010) dan 46% lebih kecil dibandingkan *Least square support vector regression*. Berdasarkan nilai RMSE, metode yang paling sesuai untuk DA adalah *Genetic algorithm support vector regression*.

4. Berdasarkan plot data aktual dan residual hasil pemodelan, data hasil prediksi berhimpit mengikuti pola data aktual. Nilai RMSE yang didapatkan untuk DAC adalah :
  - Perez (2017)        RMSE = 2,11222
  - LSSVR                RMSE = 1,67209
  - GASVR                RMSE = 1,55431

Nilai RMSE yang didapatkan untuk metode *Least square Support vector regression* sebesar

1,67209 untuk DAC yang lebih kecil 21% dibandingkan metode regresi yang digunakan dalam penelitian Pérez-Rave et al. (2017). Sedangkan nilai RMSE untuk metode *Genetic algorithm support vector regression* sebesar 1,554310 yang lebih kecil 26% dibandingkan metode regresi pada penelitian Pérez-Rave et al. (2017) dan 7% lebih kecil dibandingkan *Least square support vector regression*. Berdasarkan nilai RMSE, metode yang paling sesuai untuk DAC adalah *Genetic algorithm support vector regression*.

4. Untuk DA, kesimpulan diagram kontrol residual yang dihasilkan dari pemodelan *Least square support vector regression* sama dengan penelitian Gani et al. (2010) yaitu masih terdapat satu data yang berada diluar batas kontrol. Sedangkan berdasarkan diagram kontrol residual yang dihasilkan dari pemodelan *Genetic algorithm support vector regression* lebih baik dibandingkan *support vector regression* untuk DA. Pada data penelitian Gani et al. (2010) dengan menggunakan *support vector regression* dan *Least square support vector regression* ada satu titik data terdapat diluar batas kontrol, sedangkan diagram kontrol residual yang dihasilkan dari pemodelan *Genetic algorithm support vector regression* semua data di dalam batas kontrol.
5. Berdasarkan diagram kontrol residual yang dihasilkan dari pemodelan, *Least square support vector regression* lebih baik dibandingkan dengan menggunakan metode regresi untuk DAC. Pada penelitian Pérez-Rave et al. (2017) ada satu titik data terdapat pada batas kontrol sedangkan pada penelitian ini semua data di dalam batas kontrol. Berdasarkan diagram kontrol residual yang dihasilkan dari pemodelan *Genetic algorithm support vector regression* lebih baik dibandingkan dengan menggunakan metode regresi untuk DAC. Pada penelitian Pérez-Rave et al. (2017) ada satu titik data terdapat pada batas kontrol sedangkan pada penelitian ini semua data di dalam batas kontrol.
6. Nilai RMSE yang lebih kecil menandakan metode yang digunakan lebih sesuai untuk data, metode yang sesuai dapat mempengaruhi kinerja diagram kontrol. Nilai *residual* akan semakin mendekati nol ketika model yang dipakai semakin sesuai karena hasil prediksi akan mendekati nilai aktualnya. Rata- rata akan berkisar pada nol ketika semakin banyak nilai *residual* yang mendekati nol dan titik data akan menyebar disekitar nilai rata- rata sehingga tidak akan terjadi tipe *error* I. Tidak adanya tipe *error* I akan berdampak pada jumlah produk yang tidak akan ditolak ketika produk tersebut baik sehingga akan meningkatkan pendapatan perusahaan.

## 6.2 Saran

Saran bagi perusahaan dan bagi penelitian selanjutnya adalah sebagai berikut:

1. Pengawasan proses produksi agar dilakukan dengan inspeksi secara langsung serta menggunakan diagram kontrol, jika hasil pengawasan menggunakan diagram kontrol menunjukkan keadaan tidak terkontrol, selanjutnya dilakukan uji autokorelasi agar dapat diketahui apakah terdapat autokorelasi pada data.
2. Dalam mengatasi adanya autokorelasi, diharapkan dilakukan pemodelan terhadap data terlebih dahulu agar dihasilkan residual yang tidak berautokorelasi untuk diplotkan pada diagram kontrol.
3. Pada penelitian selanjutnya agar menggunakan data yang lebih banyak dikarenakan metode *machine learning* seperti *support vector regression* akan lebih baik jika data semakin banyak.
4. Pada penelitian selanjutnya diharapkan menggunakan lebih banyak metode sehingga akan didapatkan metode yang benar- benar menggambarkan data sehingga didapatkan diagram kontrol dengan kinerja yang lebih baik lagi.

**(Halaman ini sengaja dikosongkan)**

## DAFTAR PUSTAKA

- Alwan, L. C., & Roberts, H. V. (1988). Time-Series Process Modeling for Statistical Control. *Journal of Business Economics and Statistics*, 6(1), 87–95. Retrieved from <http://www.jstor.org/stable/1391421>
- Arkat, J., Niaki, S. T. A., & Abbasi, B. (2007). Artificial neural networks in applying MCUSUM residuals charts for AR(1) processes. *Applied Mathematics and Computation*, 189(2), 1889–1901.
- Arkeman, Y., Herdiyeni, Y., Hermadi, I., & Laxmi, G. F. (2014). Algoritma genetika tujuan jamak (Multi-Objective Genetic Algorithms): teori dan aplikasinya untuk bisnis dan agroindustri. Bogor: IPB Press.
- Basawa, I. ., Lund, R., & Padgett, W. . (1996). A Control Chart For Processes With Correlated Subgroups.
- Bennett, K. P., & Mangasarian, O. L. (1992). Robust linear programming discrimination of two linearly inseparable sets. *Optimization Methods and Software*, 1(1), 23–34.
- Benneyan, J. C. (2001). Design , Use , and Performance of Statistical Control Charts for Clinical Process Improvement.
- Bhattacharjee, A., & Samanta, B. (2002). Practical issues in the construction of control charts in mining applications. *The Journal of The South African Institute of Mining and Metallurgy*, 173–180.
- Broersen, P. M. T. (2006). *Automatic Autocorrelation and Spectral Analysis*. Automatic Autocorrelation and Spectral Analysis. London: Springer.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167. Retrieved from <http://link.springer.com/10.1023/A:1009715923555%5Cnpapers3://publication/doi/10.1023/A:1009715923555>
- Chaturvedi, A., Dubey, A. K., & Gulati, C. (2015). Statistical Process Control for Autocorrelated Data on Grid. *Journal of Statistical Theory and Practice*, 10(3).
- Chongfuangprinya, P. (2009). *Novel Nonparametric Control Charts for Monitoring Multivariate Processes*. University of Texas at Arlington.
- Cryer, J. . (1986). *Time Series, Theory and Practice and Forecasting*. London: Chapman Hall.
- Demirkol, Ş. (2008). *Comparison of Control Charts for Autocorrelated Data*. School of Natural and Applied Sciences.
- Deo, R. C., & Samui, P. (2017). Forecasting Evaporative Loss by Least-Square Support-Vector Regression and Evaluation with Genetic Programming, Gaussian Process, and Minimax Probability Machine Regression: Case Study of Brisbane City. *Journal of Hydrologic Engineering*, 22(6). Retrieved from <http://ascelibrary.org/doi/10.1061/%28ASCE%29HE.1943-5584.0001506>
- Du, S., & Lv, J. (2013). Minimal Euclidean Distance Chart based on Support Vector Regression for Monitoring Mean Shifts of Autocorrelated Processes. *International Journal of Production Economics*, 141(1), 377–387.
- Fernandez-Lozano, Francisco, C., Rivero, D., Dorado, J., Andrade Garda, J., Pazos, A., & Gestal, M. (2016). Using Genetic Algorithms to Improve Support Vector Regression in the Analysis of Atomic Spectra of Lubricant Oils. *Engineering Computations*, 33(4),

995–1005.

- Gani, W., Taleb, H., & Limam, M. (2010). Support Vector Regression based Residual Control Charts. *Journal of Applied Statistics*, 37(2), 309–324.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis (7th Edition)*. Vectors (Seventh). Prentice-Hall, Inc.  
<http://doi.org/10.1016/j.ijpharm.2011.02.019>
- Harris, T. J., & Ross, W. H. (1991). Statistical Process Control Procedures for Correlated Observations. *The Canadian Journal of Chemical Engineering*, 69(1), 48–57.
- Holland, J. H. (1975). Adaptation in Natural and Artificial Systems: An introductory Analysis with Applications to Biology, Control and Artificial Intelligence. *MIT Press*, 183. Retrieved from <http://www.citeulike.org/group/664/article/400721>
- Issam, B. K., & Mohamed, L. (2008). Support vector regression based residual MCUSUM control chart for autocorrelated process. *Applied Mathematics and Computation*, 201(1–2), 565–574.
- Johnson, R. A., & Wichern, D. W. (2007). *Applied Multivariate Statistical Analysis (6th Edition)*. The design and statistical analysis of animal experiments. New Jersey: Prentice Hall.
- Juran, J. M., & Godfrey, A. B. (1998). *Juran's Quality Control Handbook (5th Edition)*. McGrawHill. New York: McGraw-Hill. Retrieved from <http://www.worldcat.org/oclc/17546189>
- Kandananond, K. (2014). Guidelines for applying statistical quality control method to monitor autocorrelated processes. *Procedia Engineering*, 69, 1449–1458.
- Karaoglan, A. D. (2010). *Regression Control Chart for Autocorrelated Data*. Dokuz Eylül.
- Karaoglan, A. D., & Bayhan, G. M. (2011). Performance Comparison of Residual Control Charts for Trend Stationary First Order Autoregressive Processes. *Gazi University Journal of Science*, 24(2), 329–339.
- Karatzoglou, A., Meyer, D., & Hornik, K. (2006). Support Vector Algorithm in R. *Journal of Statistical Software*, 15(9), 1–28.
- King, J. D. (2008). *Monitoring the Process Mean of Autocorrelated Data*. Georgia Southern University.
- Krajewski, L. J., Ritzman, L. P., & Malhotra, M. K. (2013). *Operations Management, Process And Supply Chains (10th Edition)*. New York: Pearson.
- Leksakul, K., Holimchayachotikul, P., & Sopadang, A. (2015). Forecast of Off Season Longan Supply using Fuzzy Support Vector Regression and Fuzzy Artificial Neural Network. *Computers and Electronics in Agriculture*, 118, 259–269.
- MacCarthy, B. L., & Wasusri, T. (2002). A review of non-standard applications of statistical process control (SPC) charts. *International Journal of Quality & Reliability Management*, 19(3), 295–302.
- Magaji, A. A., Yahaya, A., & Asiribo, O. E. (2015). Assessing the Effects of Autocorrelation on the Performance of Statistical Process Control Charts, 3(6), 15–23.
- Montgomery, D. (2009). *Introduction to Statistical Quality Control*.
- Montgomery, D. C. (2013). *Introduction to Statistical Quality Control (7th Edition)* (Vol. 53). Arizona: Wiley.
- Omar, M. H. (2010). Statistical Process Control Charts for Measuring and Monitoring Temporal Consistency of Ratings. *Journal of Educational Measurement*, 47(1), 18–35.
- Pan, J. N., Li, C. I., & Wu, J. J. (2016). A new approach to detecting the process changes for


- multistage systems. *Expert Systems with Applications*, 62, 293–301. Retrieved from <http://dx.doi.org/10.1016/j.eswa.2016.06.037>
- Pérez-Rave, J., Muñoz-Giraldo, L., & Correa-Morales, J. C. (2017). Use of control charts with regression analysis for autocorrelated data in the context of logistic financial budgeting. *Computers and Industrial Engineering*, 112, 71–83.
- Psarakis, S. (2007). SPC Procedures for Monitoring Autocorrelated Processes. *SPC Procedures for Monitoring Autocorrelated Processes*, 4(4), 501–540.
- Psarakis, S., & Papaleonida, G. E. (2007). SPC Procedures for Monitoring Autocorrelated Processes. *Quality Technology and Quantitative Management*, 4(4), 501–540.
- Refaeilzadeh, P., Tang, L., & Liu, H. (2016). Cross Validation.
- Reid, R. D., & Sanders, N. R. (2011). *Operations Management. Journal of Chemical Information and Modeling* (Vol. 53). New York: John Wiley & Sons, Inc.
- Salehi, M., Kazemzadeh, R. B., & Salmasnia, A. (2012). On Line Detection of Mean and Variance Shift using Neural Networks and Support Vector Machine in Multivariate Processes. *Applied Soft Computing Journal*, 12(9), 2973–2984. Retrieved from <http://dx.doi.org/10.1016/j.asoc.2012.04.024>
- Santosa, B. (2007). *Data Mining : Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Santosa, B., & Willy, P. (2011). *Metoda Metaheuristik : Konsep dan Implementasi*. (B. Santosa, Ed.). Surabaya: Penerbit Guna Widya.
- Schölkopf, B., & Smola, A. J. (2002). Learning with kernels. *Journal of the Electrochemical Society*, 129(November), 2865. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.167.5140&rep=rep1&type=pdf>
- Schölkopf, B., & Smola, A. J. (2002). *Learning with Kernels. Journal of Chemical Information and Modeling* (Vol. 53). London: The MIT Press.
- Shao, Y. E., & Lin, Y. (2013a). Applying residual control charts to identify the false alarms in a TFT-LCD manufacturing process. *Applied Mathematics and Information Sciences*, 7(4), 1459–1464. <https://doi.org/10.12785/amis/070426>
- Shao, Y. E., & Lin, Y. (2013b). Applying residual control charts to identify the false alarms in a TFT-LCD manufacturing process. *Applied Mathematics and Information Sciences*, 7(4), 1459–1464.
- Shapiro, A. S. S., & Wilk, M. B. (1965). Biometrika Trust An Analysis of Variance Test for Normality ( Complete Samples ), 52(3), 591–611.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression \*. *Statistics and Computing*, 14, 199–222.
- Suganyadevi, M. V., & Babulal, C. K. (2014). Support Vector Regression Model for the prediction of Loadability Margin of a Power System. *Applied Soft Computing Journal*, 24, 304–315. Retrieved from <http://dx.doi.org/10.1016/j.asoc.2014.07.015>
- Suykens, J., Gestel, T. V., Brabanter, J. D., Moor, B. D., & Vandewalle, J. (2002). Least Squares Support Vector Machines.
- Taylor, P., Bisgaard, S., & Kulahci, M. (2007). Quality Quandaries : The Effect of Autocorrelation on Statistical Process Control Procedures (pp. 37–41). London: Taylor & Francis.
- Thomasson, M., & Wallin, J. (2013). Cost of Poor Quality ; definition and development of a process- based framework, 1–102.




- Walpole, R. ., Myers, R. H., & Myers, S. L. (2002). *Probablity & Statistics for Engineers and Scientists*. New York: Prentice Hall.
- Woodall, W. H., & Montgomery, D. C. (1999). Research Issues and Ideas in Statistical Process Control. *Journal of Quality Technology*, 31(4), 376–386.
- Yu, J., Han, Y., Miao, M., & Huang, H. (2015). Self-related Process Residual Control Chart Based on Neural Network, (Kam), 41–43.
- Zhou, M., & Goh, T. . (2015). Effects Of Model Accuracy On Residual Control Charts.
- Zukhri, Z. (2014). *Algoritma Genetika: Metode Komputasi Evolusioner untuk Menyelesaikan Masalah Optimasi*. Yogyakarta: Penerbit ANDI.

## LAMPIRAN

Lampiran 1.a Diagram Kontrol Individual DAC



Lampiran 1.b Diagram Kontrol Individual DA



## Lampiran 2.a Uji Autokorelasi Data Aktual DAC


### Autocorrelations

Series: c.combu.ret

Lag	Autocorrelation	Std. Error <sup>a</sup>	Value	Box-Ljung Statistic	
				df	Sig. <sup>b</sup>
1	.615	.182	11.373	1	.001
2	.520	.179	19.852	2	.000
3	.430	.175	25.896	3	.000
4	.315	.171	29.263	4	.000
5	.319	.168	32.889	5	.000
6	.241	.164	35.056	6	.000
7	.011	.160	35.062	7	.000
8	-.047	.156	35.151	8	.000
9	-.069	.152	35.358	9	.000
10	-.121	.147	36.029	10	.000
11	-.153	.143	37.171	11	.000
12	-.209	.138	39.451	12	.000
13	-.312	.134	44.882	13	.000
14	-.386	.129	53.859	14	.000
15	-.338	.124	61.330	15	.000
16	-.349	.119	69.977	16	.000

a. The underlying process assumed is independence (white noise).

b. Based on the asymptotic chi-square approximation.



## Lampiran 2.b Uji Autokorelasi Data *Residual* DAC Dari Model LSSVR


### Autocorrelations

Series: resid.escal2

Lag	Autocorrelation	Std. Error <sup>a</sup>	Box-Ljung Statistic		
			Value	df	Sig. <sup>b</sup>
1	-.104	.182	.326	1	.568
2	-.144	.179	.978	2	.613
3	.292	.175	3.766	3	.288
4	-.140	.171	4.429	4	.351
5	.033	.168	4.467	5	.484
6	-.015	.164	4.476	6	.613
7	-.145	.160	5.295	7	.624
8	.180	.156	6.627	8	.577
9	-.074	.152	6.864	9	.651
10	-.176	.147	8.298	10	.600
11	-.107	.143	8.855	11	.635
12	.013	.138	8.864	12	.715
13	.000	.134	8.864	13	.783
14	-.303	.129	14.411	14	.420
15	.014	.124	14.424	15	.494
16	.111	.119	15.294	16	.503

a. The underlying process assumed is independence (white noise).

b. Based on the asymptotic chi-square approximation.




## Lampiran 2.c Uji Autokorelasi Data *Residual* DAC Dari Model GASVR

### Autocorrelations

Series: Resid.escal

Lag	Autocorrelation	Std. Error <sup>a</sup>	Box-Ljung Statistic		
			Value	df	Sig. <sup>b</sup>
1	.173	.182	.896	1	.344
2	.025	.179	.916	2	.633
3	.326	.175	4.378	3	.223
4	.095	.171	4.689	4	.321
5	.109	.168	5.115	5	.402
6	-.046	.164	5.194	6	.519
7	-.113	.160	5.697	7	.576
8	.019	.156	5.711	8	.680
9	-.081	.152	5.996	9	.740
10	-.160	.147	7.172	10	.709
11	-.101	.143	7.675	11	.742
12	-.164	.138	9.075	12	.697
13	-.250	.134	12.572	13	.481
14	-.279	.129	17.253	14	.243
15	.001	.124	17.253	15	.304
16	-.089	.119	17.812	16	.335

- The underlying process assumed is independence (white noise).
- Based on the asymptotic chi-square approximation.



### Lampiran 3.a Koding Matlab Untuk Metode Pemodelan Data Menggunakan Least Square Support Vector Regression

```
Xtrain = [];  
Ytrain = [];  
Xtest = [];  
Ytest = [];  
type = 'function estimation';  
model = initlssvm(Xtrain,Ytrain,'f',[[],[],'RBF_kernel','o']);  
[gam,sig2] = tunelssvm(model,'simplex','crossvalidatelssvm',{10,'mse'});  
[alpha,b]=trainlssvm({Xtrain,Ytrain,type,gam,sig2,'RBF_kernel','preprocess'  
'})  
Yt=simlssvm({Xtrain,Ytrain,type,gam,sig2,'RBF_kernel','preprocess'},{alpha  
,b},Xtest)  
plotlssvm({Xtrain,Ytrain,type,gam,sig2,'RBF_kernel'},{alpha,b})  
Ypred_train=simlssvm({Xtrain,Ytrain,type,gam,sig2,'RBF_kernel','preprocess'  
'},{alpha,b},Xtrain)  
Error_train = (Ytrain-Ypred_train)  
SSEtrain = Error_train.^2  
SSEtrain2 = sum(SSEtrain)  
Ypred_test=simlssvm({Xtrain,Ytrain,type,gam,sig2,'RBF_kernel','preprocess'  
'},{alpha,b},Xtest)  
Error_test = (Ytest-Ypred_test)  
SSEtest = Error_test.^2  
SSEtest2 = sum(SSEtest)  
st = controlchart(Error_train,'chart',{ 'i' })
```

### Lampiran 3.b Koding Rstudio Untuk Metode Pemodelan Data Menggunakan Genetic Algorithm Support Vector Regression

```
library(e1071)  
library(cvTools)  
setwd("E:/Baca")  
  
jumlah.bit <- function(mins1,maks1,mins2,maks2,mins3,maks3,  
                        ketelitian1,ketelitian2,ketelitian3){  
  calc.jumlah.bit <- function(Data){  
    range <- Data[2]-Data[1]  
    j <- range*(10^Data[3])  
    n <- 1  
    while ((2^n < j) && (2^(n+1) < j) ){  
      n <- n+1  
    }  
    returnValue(n+1)  
  }  
  var.1 <- c(mins1,maks1,ketelitian1)  
  var.2 <- c(mins2,maks2,ketelitian2)  
  var.3 <- c(mins3,maks3,ketelitian3)  
  var.all <- rbind(var.1,var.2,var.3)  
  nbit <- apply(var.all,1,FUN=calc.jumlah.bit)  
  returnValue(nbit)  
}
```

```

#Inisialisasi Populasi
inisialisasi <- function(nbit,npop){
  populasi <- matrix(ncol=nbit,nrow=npop)
  for ( i in 1:npop){
    populasi[i,] <- sample(0:1, nbit, replace=T)
  }
  returnValue(populasi)
}

#Konversi Biner ke Integer untuk semua variabel
bit2int <- function(populasi,nvar,mins1,maks1,mins2,maks2,mins3,maks3,
                    bit1,bit2,bit3){
  bit2int.aux <-
function(populasi,var_ke,nvar,mins1,maks1,mins2,maks2,mins3,maks3,
        bit1,bit2,bit3){
  r <- c(0,bit1,bit2,bit3)
  ranges <- c((maks1-mins1),(maks2-mins2),(maks3-mins3))
  mins <- c(mins1,mins2,mins3)
  X <- NULL
  for (i in 1:dim(populasi)[1]){
    x <- 0
    k <- 1
    for (j in (sum(r[1:var_ke])+1):(sum(r[1:(var_ke+1)]))){
      if (populasi[i,j]==1){
        x = x+2^(r[var_ke+1]-k)
        k <- k+1
      }
    }
    xint <- mins[var_ke] + (x*ranges[var_ke]/(2^r[var_ke+1]-1))
    X <- c(X,xint)
  }
  returnValue(X)
}
x <- NULL
for (i in (1:nvar)){
  aux <-
bit2int.aux(populasi,i,nvar,mins1,maks1,mins2,maks2,mins3,maks3,
            bit1,bit2,bit3)
  x <- cbind(x,x=aux)
}
returnValue(x)
}

#Seleksi ROULETTE
seleksi.roulette <- function(solusi,fitness){ #solusi biner
  sum.fitness <- sum(fitness)
  cum.prob <- matrix(ncol=1,nrow=nrow(solusi))
  prob <- 0
  for (i in 1:length(fitness)){
    prob <- prob + fitness[i]/sum.fitness
    cum.prob[i,] <- prob
  }
  random <- runif(nrow(solusi))
  new.solusi <- solusi
  for (i in 1:nrow(solusi)){
    for (j in 1:nrow(solusi)){
      if (random[i] <= cum.prob[j]){
        new.solusi[i,] <- solusi[j,]
      }
    }
  }
}

```

```

        break
    }
}
returnValue(new.solusi)
}

#Reproduksi
reproduce <- function(individu,pc,pm){ #individu adalah luaran seleksi
  #one point crossover
  crossover <- function(parent.1,parent.2){
    cutpoint <- sample(1:(length(parent.1)-1),1)
    child.1 <-
c(parent.1[1:cutpoint],parent.2[(cutpoint+1):length(parent.2)])
    child.2 <-
c(parent.2[1:cutpoint],parent.1[(cutpoint+1):length(parent.1)])
    child <- rbind(child.1,child.2)
    returnValue(child)
  }
  mutation <- function(offspring,pm){
    n.mut <- floor(pm*length(offspring)) #banyaknya yang akan dimutasi
    for (i in 1:length(n.mut)){
      x <- sample(1:nrow(offspring),1) # x dan y adalah letak offspring
yang akan dikenai mutasi
      y <- sample(1:ncol(offspring),1)
      if (offspring[x,y]==0)
        offspring[x,y]=1
      else
        offspring[x,y]=0
    }
    returnValue(offspring)
  }

  rn <- runif(nrow(individu),0,1) #Membangkitkan bilangan acak untuk tiap
kromosom
  p.index <- NULL #Memilih kromosom sebagai parent
  for ( i in 1:length(rn)){
    if (rn[i] < pc)
      p.index <- c(p.index,i)
  }
  n.p.index <- length(p.index)
  if (n.p.index%%2!=0){ #Jika banyak parent yang terpilih ganjil, maka
yang terakhir dibuang
    p.index <- p.index[-n.p.index]
    n.p.index <- n.p.index-1
  }

  if (length(p.index)==0){ #Tidak ada yang dipindahsilang
    offspring <- individu
  } else {
    offspring <- individu
    for(i in seq(1, n.p.index, by = 2)){ #Proses crossover
      child <- crossover(individu[p.index[i],],individu[p.index[i+1],])
      offspring[p.index[i],] <- child[1,]
      offspring[p.index[i+1],] <- child[2,]
    }
  }
}

```



```

    offspring.mutation <- mutation(offspring,pm)
    return value(offspring.mutation)
}

#Fitness
fitness <- function(dataset,solusi){
  calc.rmse <- function(parameter.svr,dataset,K=5){
    Kfold <- cvFolds(nrow(dataset),K=K)
    rmse.folds <- matrix(ncol=2,nrow=K)
    indeks.test <- matrix(ncol=nrow(dataset)/K,nrow=K)
    for (i in 1:K){
      indeks.train <- Kfold$subsets[which(Kfold$which!=i)]
      indeks.test[i,] <- Kfold$subsets[which(Kfold$which==i)]
      data.train <- dataset[indeks.train,]
      data.test <- dataset[indeks.test[i,],]
      svr.model <- svm(Y1 ~ . ,
data=data.train,kernel="radial",gamma=parameter.svr[1],cost=parameter.svr[
2],epsilon=parameter.svr[3])
      rmse.train <- sqrt(mean(svr.model$residuals^2))
      pred <- predict(svr.model,data.test[,2:ncol(data.test)])
      rmse.test <- sqrt(mean((data.test["Y1"]-pred)^2))
      rmse.folds[i,] <- c(rmse.test,rmse.train)
    }
    id.min <- which(rmse.folds[,1]==min(rmse.folds[,1]))
    return value(c(rmse.folds[id.min,],indeks.test[id.min,]))
  }
  rmse <- apply(solusi,1,FUN=calc.rmse,dataset=dataset)
  rmse.t <- t(rmse)
  fitness.value <- 1/(1+rmse.t[,1])
  result <- cbind(fitness.value,rmse.t[,1],rmse.t[,2])
  colnames(result) <- c("fitness",'rmse.test','rmse.train')
  data <- rmse.t[,3:ncol(rmse.t)]
  return value(list('fitness'=result,'data'=data))
}

#PARAMETER GENETIC ALGORITHM
npop <- 20 #25
nvar <- 3
mins1 <- 2^-10;maks1 <- 2^10 #gamma #2^-1 sd 2^2
mins2 <- 2^-10;maks2 <- 2^10 #cost ##2^-1 sd 2^2
mins3 <- 2^-5;maks3 <- 1 #1.92553 #2.04211 #Epsilon - Max

ketelitian1 <- 3; ketelitian2 <- 3; ketelitian3 <- 3
pc <- 0.9
pm <- 0.01
max.iter <- 100
nbit <-
jumlah.bit(mins1,maks1,mins2,maks2,mins3,maks3,ketelitian1,ketelitian2,ket
elitian3)
bit1 <- nbit[1];bit2 <- nbit[2];bit3 <- nbit[3]
total.bit <- sum(nbit)

#LOAD DATA
Training <- "E:/Baca/Coba/Research Teknik Industri
(Hasan)/TransformedDatasets_CC_2017/TransformedDatasets_CC_2017/Training
sample c_combu_ret.txt"

```

```

Testing <- "E:/Baca/Coba/Research Teknik Industri
(Hasan)/TransformedDatasets_CC_2017/TransformedDatasets_CC_2017/Validation
sample c_combu_ret.txt"
Training_dataset <- read.table(Training,heade=T)
Testing_dataset <- read.table(Testing,header=T)

Dataset <- rbind(Training_dataset,Testing_dataset)
K <- 5

#MAIN PROCESS
solusi.int.best <- matrix(ncol=nvar, nrow=max.iter)
colnames(solusi.int.best) <- c("gamma","cost","epsilon")
ga.summary <- matrix(ncol=(nvar+3),nrow=max.iter)
colnames(ga.summary) <-
c("gamma","cost","epsilon","fitness","rmse.test","rmse.train")
fit.summary <- matrix(ncol=2,nrow=max.iter)
colnames(fit.summary) <- c("max.fit","mean.fit")
populasi <- inisialisasi(total.bit,npop)
saved.test.data <- matrix(ncol=nrow(Dataset)/K,nrow=max.iter)
for (i in 1:max.iter){
  print(paste('iteration - ',i,sep=""))
  int.populasi <-
bit2int(populasi,nvar,mins1,maks1,mins2,maks2,mins3,maks3,
         bit1,bit2,bit3)
  fitness.value <- fitness(Dataset,int.populasi)
  indeks <-
which(fitness.value$fitness[,1]==max(fitness.value$fitness[,1]))
  parent <- seleksi.roulette(populasi,fitness.value$fitness[,1])
  new.individu <- reproduce(parent,pc,pm)
  populasi <- new.individu
  solusi.int.best [i,] <- int.populasi[indeks[1],]
  saved.test.data[i,] <- fitness.value$data[indeks[1],]
  fit.summary[i,] <-
c(max(fitness.value$fitness[,1]),mean(fitness.value$fitness[,1]))
  ga.summary[i,] <-
c(int.populasi[indeks[1],],fitness.value$fitness[indeks[1],])
}
ga.summary
min(ga.summary[,5])
max(ga.summary[,5])
min(ga.summary[,6])
max(ga.summary[,6])
loc.data <- which(ga.summary[,5]==min(ga.summary[,5]))
index.test.data <- saved.test.data[loc.data,]
parameter_optimal <- ga.summary[loc.data,1:3]
Data_train_solution <- Dataset[-index.test.data,]
Data_test_solution <- Dataset[index.test.data,]

write.csv(Data_train_solution,file="Data Training Selected.csv")
write.csv(Data_test_solution,file="Data Testing Selected.csv")
write.csv(ga.summary,file='Solusi Each Generation.csv')
write.csv(parameter_optimal,file='Optimal Parameter.csv')

#Re-Run Model using Optimal Parameter generated using GA
svr.model <- svm(Y1 ~ . ,
data=Data_train_solution,kernel="radial",epsilon=parameter_optimal['epsilo
n'],cost=parameter_optimal['cost'],

```

```

        gamma=parameter_optimal['gamma'])
RMSE.training <- sqrt(mean(svr.model$residuals^2))
RMSE.training
#Testing Process
pred <- predict(svr.model,Data_test_solution[,2:ncol(Data_test_solution)])
RMSE.Testing <- sqrt(mean((Data_test_solution["Y1"]-pred)^2))
RMSE.Testing
RMSE.all <- c(RMSE.training,RMSE.Testing)
names(RMSE.all) <- c("RMSE Training", 'RMSE Testing')
write.csv(svr.model$residuals, 'Residual Model Training.csv')
write.csv((Data_test_solution["Y1"]-pred), 'Residual Testing.csv')
write.csv(RMSE.all, file='RMSE Training & Testing.csv')


pdf('Fitness Plot.pdf')
plot(fit.summary[,1], col='red', type='l', ylab =
'Fitness', xlab='Generations', ylim=c(0.3,0.7))
points(fit.summary[,2], type='l', col='blue')
mtext('Fitness Plot',
      side=3, outer=TRUE, line=-3, cex=2)
legend('bottomright', legend=c("Maximum Fitness", "Average
Fitness"), col=c("red", "blue"), cex=1,
      horiz=F, box.lty=2, bty='n', pch=c(15,15))
dev.off()

Residual.test <- unlist(Data_test_solution["Y1"]-pred)
Residual.train <- as.vector(svr.model$residuals)
Residual.all <- c(Residual.train, Residual.test)


pdf('Plot Residual.pdf')
plot(Residual.all, type='l', ylim=c(-2,2), ylab='Residual values')
abline(a=mean(Residual.all), b=0, col='blue')
abline(a=mean(Residual.all)+3*sqrt(var(Residual.all)), b=0, col='red')
abline(a=mean(Residual.all)-3*sqrt(var(Residual.all)), b=0, col='red')
mtext('Residual Control Chart',
      side=3, outer=TRUE, line=-3, cex=2)
dev.off()

```

#### Lampiran 4.a Fitness Plot Tiap Iterasi DAC



#### Lampiran 4.b Fitness Plot Tiap Iterasi DA



## BIOGRAFI PENULIS



Penulis bernama Hasan Bisri, lahir pada Juli 1992 di Gresik. Penulis merupakan putra ketiga dari Bapak Busron dan Ibu Kamsiyatun. Penulis menempuh pendidikan mulai dari TK, MI dan MTs di Wotan, Gresik. Selanjutnya SMA di Surabaya. Setelah lulus SMA, penulis melanjutkan pendidikan ke jenjang proram Strata-1 di Program Studi Statistika Universitas Brawijaya Malang angkatan 2011. Penulis aktif pada kegiatan Lab di Universitas Brawijaya Malang. Selain itu, penulis juga pernah menjadi anggota Asisten Laboratorium pada beberapa mata kuliah. Yang pada akhirnya penulis memutuskan untuk melanjutkan pendidikan ke jenjang Program Strata-2 di Jurusan

Teknik Industri ITS pada Bidang Konsentrasi Manajemen Kualitas dan Manufaktur. Penulis resmi menjadi mahasiswa ITS pada September 2016. Alhamdulillah, selama berkuliah di ITS penulis mendapatkan teman-teman yang saling support dan saling berbagi pengalaman, sehingga penulis memiliki banyak pengalaman. Untuk informasi lebih lanjut penulis dapat dihubungi melalui email [hassanbissri92@gmail.com](mailto:hassanbissri92@gmail.com)